



Тема доклада:

«Обучение по нескольким образцам в задаче
классификации ЭКГ»

Выполнили:
студенты ИИТММ гр. 3823М1ФИи1
Преображенская Ю.Д.,
Кулемин П.А.

Основные проблемы современных глубоких нейронных сетей:

- Требование большого объема данных;
- Дисбаланс имеющихся данных.




Рис.1. Кол-во данных по 6 классам в датасете MIT-BIH arrhythmia database

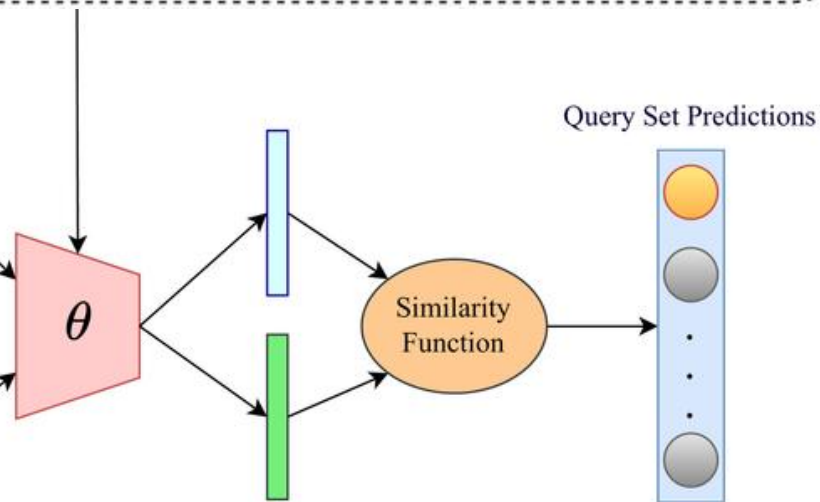


Цель: Необходимо «научить» нейронную сеть хорошо обобщать данные и извлекать полезную информацию даже из небольшого количества примеров.

Решение: Использование различных методов обучения по нескольким образцам (Few-Shot Learning) для решения задачи классификации сигналов ЭКГ.

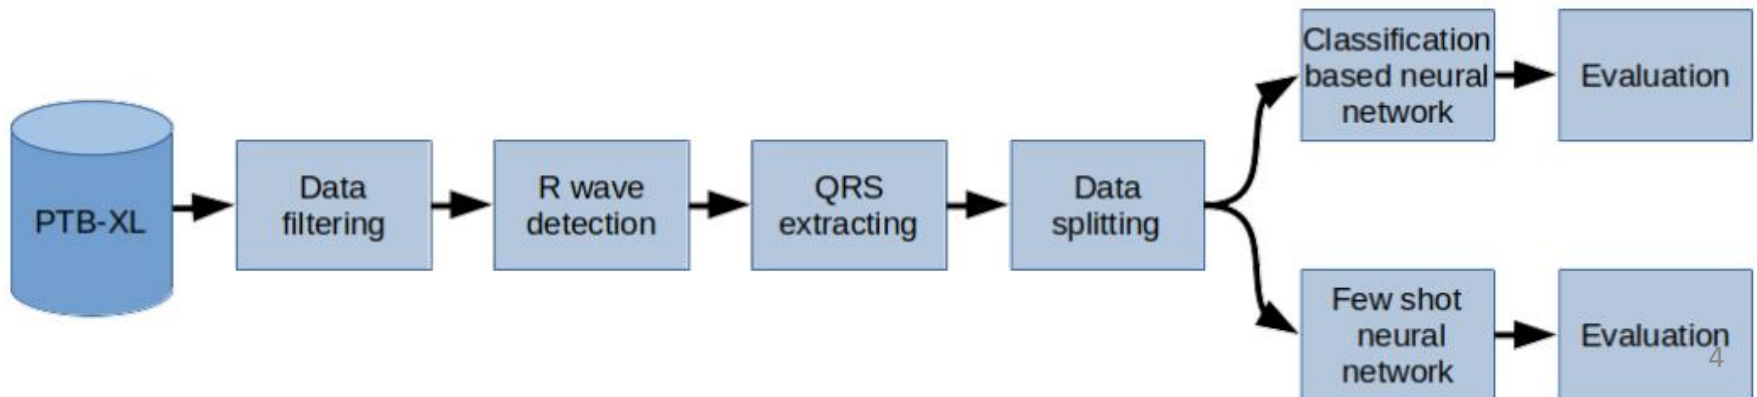
Основные этапы:

- Предобучение
- Дообучение

Supervised Learning



- **Название статьи:** «Study of the Few-Shot Learning for ECG Classification Based on the PTB-XL Dataset»
- **Год публикации:** 2022
- **Опубликована в:** *Sensors* 2022, 22(3), 904; <https://doi.org/10.3390/s22030904>
- **Основные идеи:**
 - Применение различных детекторов для нахождения R-пиков и использование алгоритма k-средних для получения консенсуса между детекторами;
 - Использование триплетной функции потерь при обучении;
 - При валидации разделение данных на наборы поддержки и запроса и вычисление расстояния между вектором образца запроса и средним вектором каждого класса набора поддержки.




• Результаты:

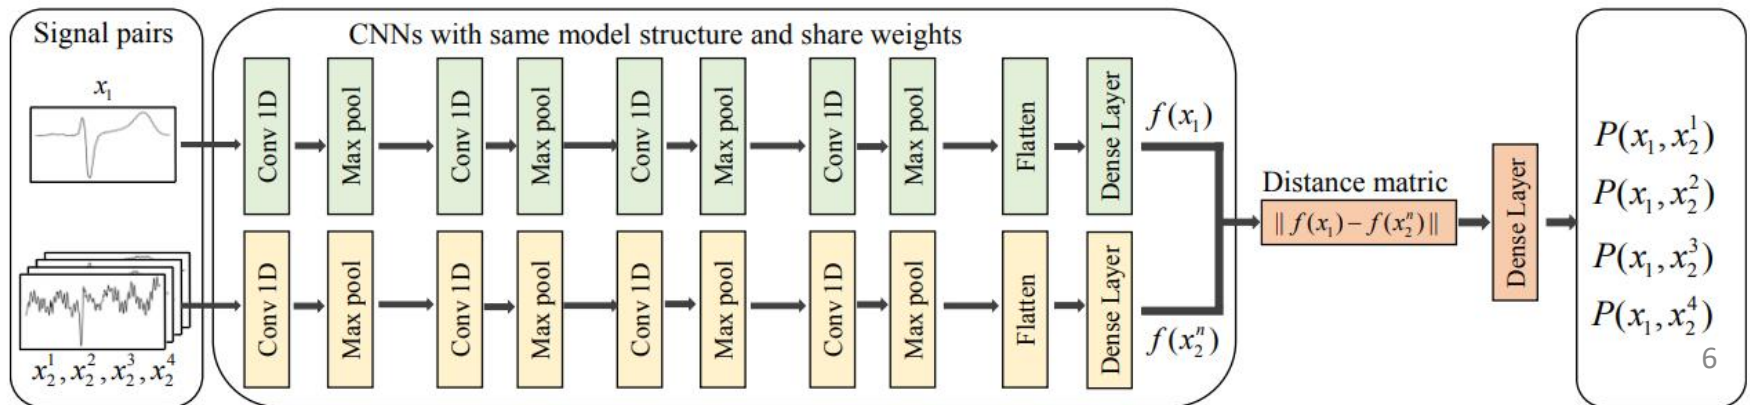
- Классификация на 2 класса: FSL = 91.3% vs Softmax = 89.7%
- Классификация на 5 классов: FSL = 79.0% vs Softmax = 75.8%
- Классификация на 20 класса: FSL = 65.8% vs Softmax = 67.1%

• Выводы:

- Алгоритм показывает довольно низкие результаты, особенно на классификации больше, чем на два класса.
- Возможно, авторами использовалась не слишком удачная архитектура сети и стоит заменить ее на другую, сохраняя при этом описанный подход обучения и валидации.



- **Название статьи:** «A One-Dimensional Siamese Few-Shot Learning Approach for ECG Classification under Limited Data»
- **Задача:** классификация аритмии на датасете MIT-BIH
- **Год публикации:** 2021
- **Опубликована в:** *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*
- **Основные идеи:**
 - Использование сиамской нейронной сети на основе двух одинаковых сверточных сетей с общими весами для извлечения признаков;
 - Вычисление в процессе обучения L1 расстояния между векторами признаков пар сигналов для получения матрицы вероятностей того, что сигналы принадлежат к одному классу.



- **Результаты:**

Accuracy (%)	1 shot	5 shot	10 shot	30 shot	50 shot
VGG 12	52.90	70.40	70.78	74.48	79.08
LSTM	62.05	69.15	74.53	79.83	80.40
CNN-LSTM	67.35	73.95	74.35	74.43	78.56
1D-SIAMESE	82.36	84.98	89.16	91.73	92.42

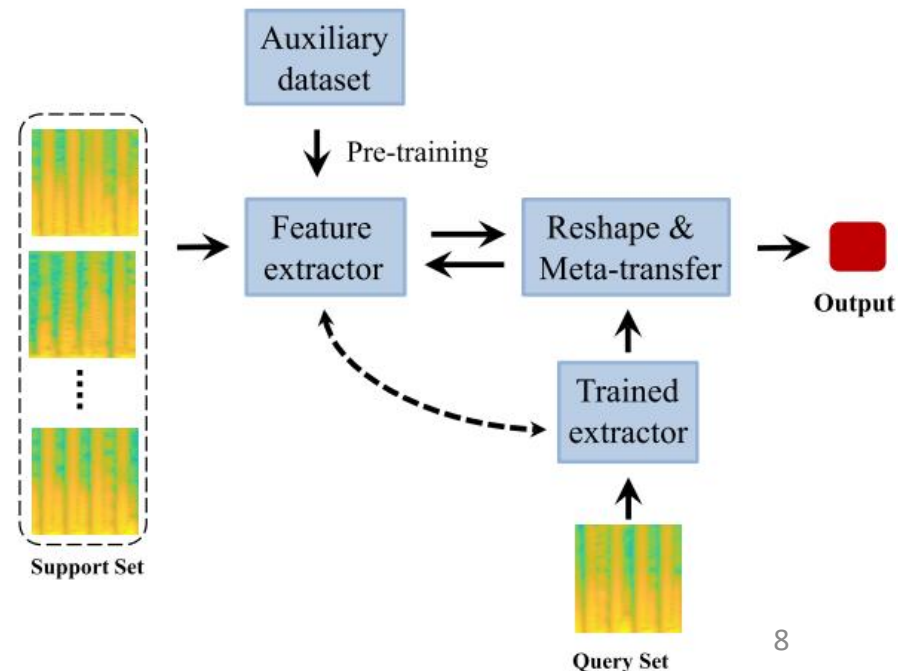
Классификация на 4 класса:

normal beat (N), left bundle branch block beat (L), right bundle branch block beat (R), premature ventricular contraction (V).

- **Выводы:**

- На небольшом обучающем наборе данная сеть работает лучше, чем CNN-BASE, VGG12, LSTM и CNN-LSTM.
- Чем больше тренировочных образцов на каждый класс, тем выше метрика.
- Однако, модель по-прежнему совершает значительное количество ошибок.

- **Название статьи:** «Few-shot learning for cardiac arrhythmia detection based on electrocardiogram data from wearable devices»
- **Задача:** классификация аритмии на датасетах MIT-BIH, PTB-XL
- **Год публикации:** 2021
- **Опубликована в:** *Digital Signal Processing*
- **Основные идеи:**
 - Деление данных на вспомогательный датасет, набор поддержки и набор запроса (сигналы преобразованы в частотно-временные спектрограммы с помощью преобразований Фурье);
 - 3 этапа: предобучение, изменение размерности признаков и мета-трансферное обучение;
 - В качестве сети для предобучения для извлечения признаков используется сеть EfficientNet на основе сверточной сети.
 - Имеется дополнительный сверточный слой для «отсеивания» ненужных признаков.



• Основные идеи:

- Мета-трансферное обучение состоит в обновлении претренированных весов для нового домена на основе набора поддержки и набора запроса. Для классификации используется метрический модуль на основе расстояния Махаланобиса.

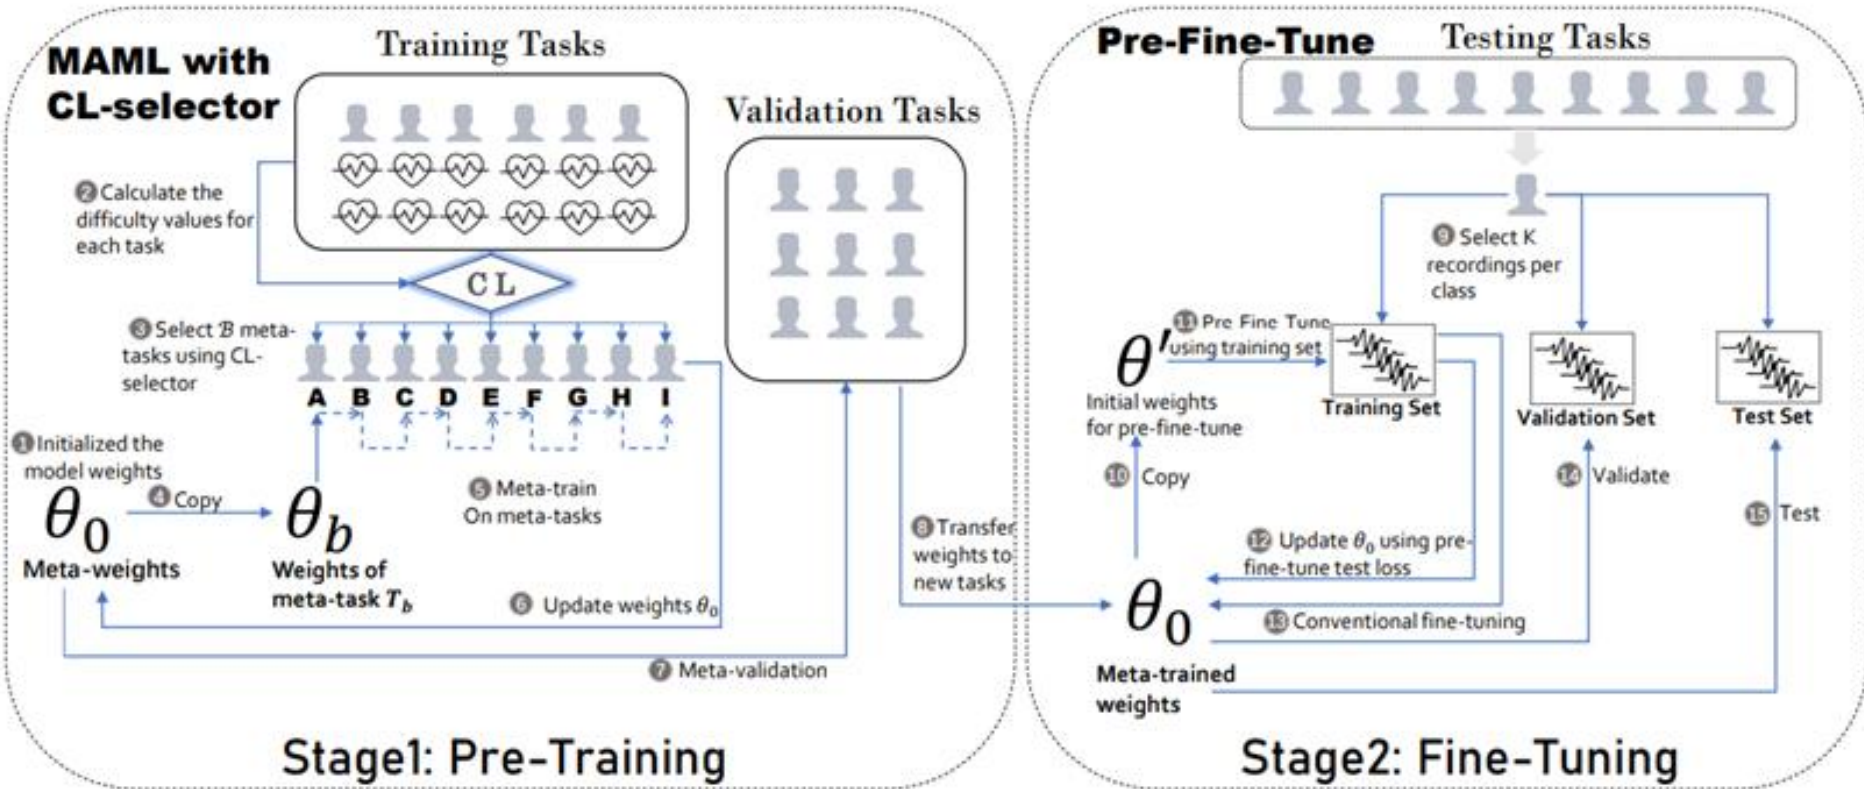
• Результаты:

Method	backbone	2-way task			4-way task		
		1-shot	5-shot	10-shot	1-shot	5-shot	10-shot
PrototyNet [37]	Conv-4	91.5±0.4	94.4±0.8	96.2±0.4	89.7±0.5	92.3±0.2	93.7±0.4
Relation-Net [48]	Conv-4	91.3±0.2	91.1±1.3	96.1±1.9	92.5±1.3	92.1±1.2	93.9±1.8
MatchingNet [31]	Conv-4	85.7±2.3	87.5±3.3	87.1±4.1	85.5±1.9	86.7±2.1	91.8±2.7
MatchingNet($\ell=2$)	Conv-4	83.8±5.1	85.6±3.3	90.0±3.5	87.3±2.1	91.5±1.7	91.4±2.0
Meta-learning [30]	Conv-4	88.3±1.6	90.1±2.3	90.5±1.3	92.1±1.5	93.7±1.2	92.5±1.0
Without pre-train	EffiNet-b0	90.9±2.7	91.8±3.2	94.7±1.8	89.1±0.7	93.5±0.7	92.7±0.6
Pre-training ($\lambda = 3$)	EffiNet-b0	90.4±1.0	90.1±1.9	94.1±1.7	90.0±2.1	93.0±1.3	91.9±1.6
Our method	EffiNet-b0	93.3±0.3	96.3±0.8	97.0±0.4	90.9±1.8	93.8±0.6	95.6±0.3

• Выводы:

- Предложенный авторами подход обходит по точности базовые методы в задаче обучения по нескольким образцам для классификации ЭКГ.
- Стратегия мета-трансферного обучения позволяет использовать полученные ранее знания.
- Однако, поскольку авторами решалась одна из наиболее простых задач в этой области, на более сложных доменах данный подход может работать не слишком хорошо.

- **Название статьи:** «MetaVA: Curriculum Meta-learning and Pre-fine-tuning of Deep Neural Networks for Detecting Ventricular Arrhythmias based on ECGs»
- **Задача:** классификация аритмии желудочков на датасетах MIT-BIH arrhythmia database, MIT-BIH malignant ventricular arrhythmia database, CUDB
- **Год публикации:** 2022
- **Опубликована:** *arXiv preprint*
- **Основные идеи:**
 - 2 этапа: предварительное обучение на большом тренировочном наборе и тонкая настройки («Fine-Tuning»);
 - Объединение метода модельно-независимого мета-обучения (MAML) и стратегии обучения по учебной программе (Curriculum Meta-learning, или сокращенно CL), имитирующей процесс обучения от простого к сложному.
 - Модуль CL используется для отбора задач в процессе обучения (для каждой задачи высчитывается значение сложности, чтобы получить подходящий порядок изучения).
 - Обученные веса передаются на этап тонкой настройки, где они обновляются для рассматриваемого домена.
 - Используется модель ResNeXt.



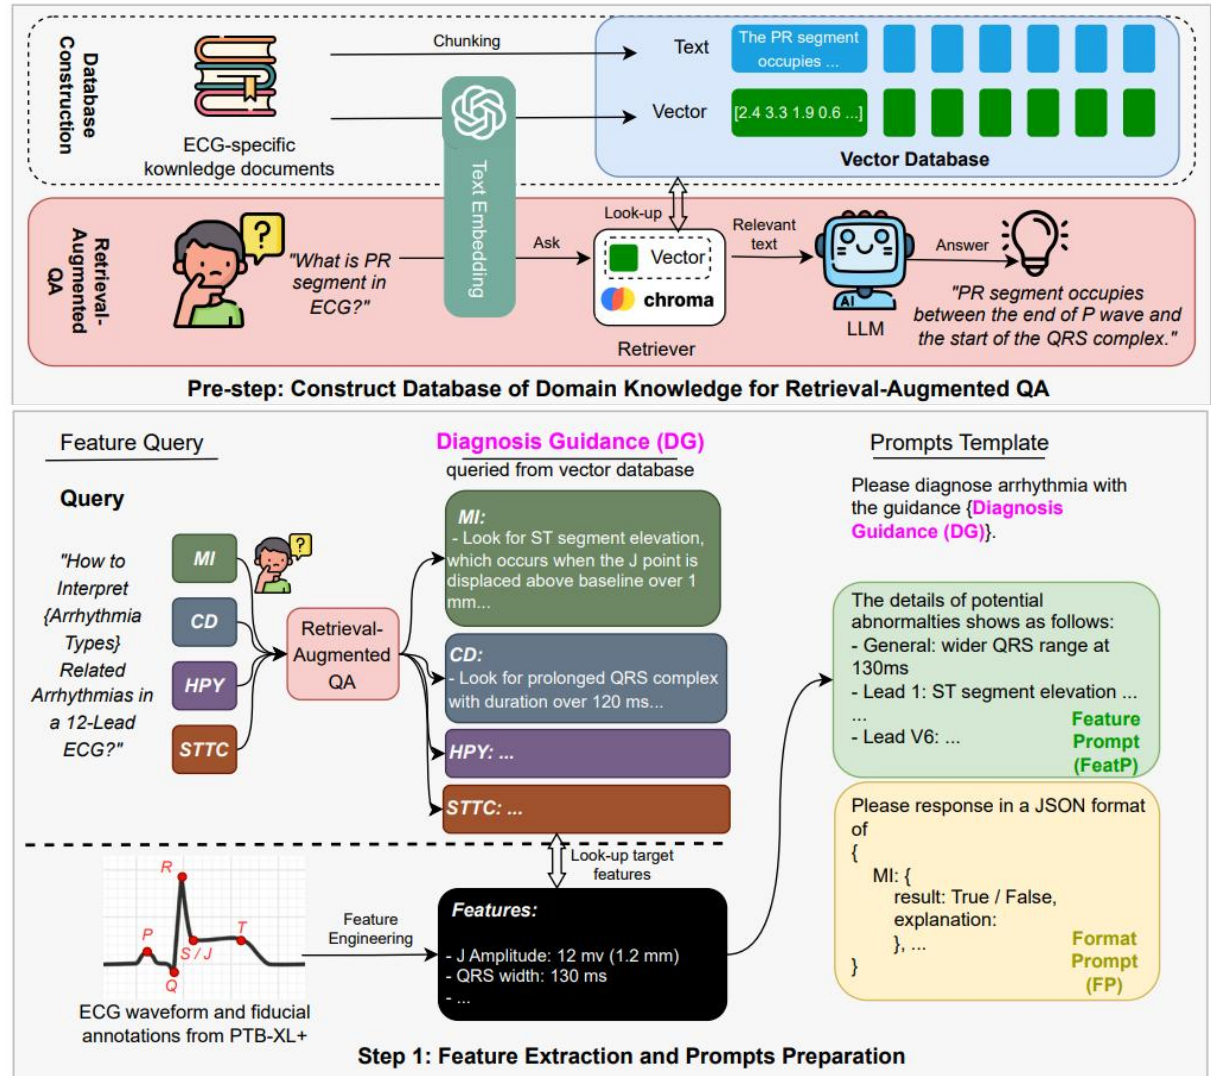
- **Результаты:**

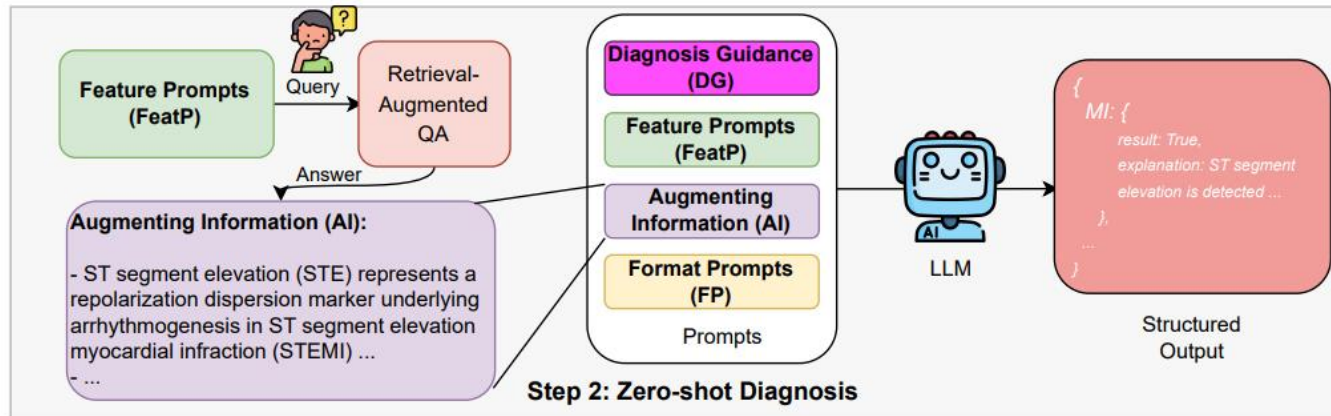
Method	ROC-AUC	Accuracy	PR-AUC	F1-score
MetaVA	0.9843±0.0041	0.9602±0.0060	0.9681±0.0126	0.9173±0.0057
MC+F	0.9742±0.0061	0.9549±0.0089	0.9512±0.0218	0.9064±0.0150
M+PF	0.9823±0.0103	0.9572±0.0076	0.9588±0.0248	0.9156±0.0076
M+F	0.9703±0.0093	0.9497±0.0132	0.9423±0.0185	0.8902±0.0171
Vanilla	0.9566±0.0056	0.9392±0.0141	0.9025±0.0269	0.8833±0.0181

- **Выводы:**

- Результаты выше, чем другие рассмотренные ранее методы (возможно, благодаря более удачной архитектуры самой сети или за счет модуля отбора задач);
- Авторами статьи были приведены псевдокоды предложенных ими модулей, что может помочь в реализации их подхода;

- **Название статьи:** «Zero-Shot ECG Diagnosis with Large Language Models and Retrieval-Augmented Generation»
- **Задача:** классификация аритмии и апноэ во сне на датасетах PTB-XL, Арнеа-ECG
- **Год публикации:** 2023
- **Опубликована в:** *Proceedings of Machine Learning Research*





• Результаты:

○ Аритмия

Method	Model	Training	Accuracy	Macro Precision	Macro Recall	Macro F1
Supervised	1D-CNN	17441	0.748	0.708	0.643	0.660
<i>Few-shot TNP</i> (Li et al., 2023)	LLaMA2-7B	25	0.417	0.391	0.277	0.357
	LLaMA2-13B	25	0.422	0.401	0.294	0.348
<i>Zero-shot RAG</i>	LLaMA2-7B	0	0.714	0.765	0.548	0.617
(Ours)	LLaMA2-13B	0	0.726	0.770	0.561	0.622
	GPT-3.5	0	0.757	0.791	0.616	0.669

○ Апноэ во сне

Method	Model	Training	Accuracy	Precision	Recall	F1
Supervised	1D-CNN	17233	0.821	0.804	0.843	0.787
<i>Few-shot TNP</i> (Li et al., 2023)	LLaMA2-7B	25	0.675	0.492	0.535	0.504
	LLaMA2-13B	25	0.691	0.512	0.562	0.522
<i>Zero-shot RAG</i>	LLaMA2-7B	0	0.753	0.710	0.855	0.758
(Ours)	LLaMA2-13B	0	0.772	0.728	0.859	0.770
	GPT-3.5	0	0.804	0.763	0.910	0.801



Посмотри на сигнал ЭКГ. Определи диагноз по этому сигналу ЭКГ и объясни, какие признаки указывают на наличие этого диагноза в данном сигнале.



ChatGPT

На представленной ЭКГ можно наблюдать характерные признаки фибрилляции предсердий (фибрилляции атриумов). Этот диагноз можно определить по следующим ключевым признакам:

1. Отсутствие четких P-волн: На ЭКГ нет регулярных и отчетливых P-волн, которые обычно предшествуют QRS-комплексу. Вместо этого наблюдаются мелкие нерегулярные колебания линии изолинии.



Atrial fibrillation: Irregularly irregular ventricular rate without visible P waves

2. Нерегулярный ритм желудочков:

Интервалы между QRS-комплексами варьируются и являются нерегулярными. Это говорит о нерегулярном ритме сокращений желудочков.


3. Варибельная амплитуда и форма зубцов:

На ЭКГ видно, что между QRS-комплексами имеются мелкие и нерегулярные волны (волны фибрилляции), которые отличаются по амплитуде и форме.

Эти признаки в совокупности позволяют сделать вывод о наличии фибрилляции предсердий у пациента.

**Диагноз
определен
верно**

(источник:
<https://litfl.com/atrial-fibrillation-ecg-library/>)



Посмотри на сигнал ЭКГ. Определи диагноз по этому сигналу ЭКГ и объясни, какие признаки указывают на наличие этого диагноза в данном сигнале.

Диагноз определен верно

(источник: <https://multiurok.ru/blog/priznaki-infarkta-miokarda-po-ekg-sierdtsa.html>)



ChatGPT

На представленной ЭКГ можно наблюдать признаки инфаркта миокарда, вероятнее всего нижней стенки. Это определяется следующими ключевыми признаками:

1. **Элевация сегмента ST:** В отведениях II, III и aVF видна элевация сегмента ST. Это является классическим признаком острого инфаркта миокарда.
2. **Депрессия сегмента ST:** В отведениях I и aVL наблюдается депрессия сегмента ST, что может быть реципрокным изменением, часто встречающимся при нижнем инфаркте миокарда.

Эти признаки на ЭКГ указывают на наличие острого инфаркта миокарда нижней стенки сердца. Немедленная медицинская помощь и проведение реперфузионной терапии крайне важны для улучшения прогноза пациента.



Посмотри на сигнал ЭКГ. Определи диагноз по этому сигналу ЭКГ и объясни, какие признаки указывают на наличие этого диагноза в данном сигнале.

Анализ сигнала ЭКГ

На представленном графике ЭКГ можно рассмотреть следующее:

1. Регулярность и частота сердечных сокращений:

- Сигнал демонстрирует регулярные R-зубцы, что свидетельствует о синусовом ритме.
- Частота сердечных сокращений (ЧСС) кажется относительно стабильной, что характерно для нормального синусового ритма.

2. Форма и амплитуда R-зубцов:

- R-зубцы имеют значительную амплитуду, которая значительно превышает амплитуды других волн (P и T волн), что является нормальным для здорового сердца.

3. Отсутствие значительных артефактов:

- Сигнал кажется чистым, без значительных шумов или артефактов, что позволяет сделать более точные выводы о ритме.

Возможный диагноз:

- **Нормальный синусовый ритм:** Сигнал ЭКГ демонстрирует регулярный синусовый ритм без видимых признаков аритмий, тахикардии или брадикардии.


Обоснование:

- **Регулярные R-зубцы с постоянными интервалами:** Это указывает на регулярную деятельность синусового узла, что характерно для нормального сердечного ритма.
- **Отсутствие аномальных волн:** Нет признаков патологических волн, таких как фибрилляция, трепетание или экстрасистолы.

Таким образом, представленный сигнал ЭКГ не показывает признаков каких-либо патологий и может быть интерпретирован как нормальный синусовый ритм. Для более детальной диагностики и исключения скрытых патологий рекомендуется проведение более длительного мониторинга или дополнительных исследований.

Диагноз определен верно

(источник: датасет LUDB)



Посмотри на сигнал ЭКГ. Определи диагноз по этому сигналу ЭКГ и объясни, какие признаки указывают на наличие этого диагноза в данном сигнале.

На изображении представлена 12-канальная электрокардиограмма (ЭКГ). Основные признаки, которые можно выделить на данной ЭКГ:

1. Узкие комплексы QRS:

- Комплексы QRS узкие и регулярные, что указывает на наличие нормального пути проведения импульсов через желудочки.

2. Высокие и заостренные зубцы Т в отведениях V1-V4:

- Высокие заостренные зубцы Т в правых грудных отведениях (V1-V4) могут указывать на гиперкалиемию.

3. Отсутствие значительных патологических Q-зубцов:

- Не видно патологических зубцов Q, что исключает острый инфаркт миокарда.

4. Нормальные интервалы PR и QT:

- Интервалы PR и QT в пределах нормы, что исключает блокады и удлинение интервала QT.

5. Подъем сегмента ST в отведении V1:


- Легкий подъем сегмента ST в отведении V1 может указывать на раннюю реполяризацию или перикардит.

На основании перечисленных признаков наиболее вероятным диагнозом является **гиперкалиемию**. Высокие заостренные зубцы Т в правых грудных отведениях являются ключевым признаком этого состояния.

Диагноз определен неверно

(Правильный диагноз: Апикальная гипертрофическая кардиомиопатия)

источник: <https://litfl.com/apical-hypertrophic-cardiomyopathy-ah>



Посмотри на сигнал ЭКГ. Определи диагноз по этому сигналу ЭКГ и объясни, какие признаки указывают на наличие этого диагноза в данном сигнале.

На изображении представлена электрокардиограмма (ЭКГ), которая демонстрирует значительные изменения ритма и амплитуды сигнала. Основные признаки, которые можно выделить на данной ЭКГ:

1. Отсутствие нормальных зубцов P и комплексов QRS:

- Зубцы P не видны, что может указывать на отсутствие нормального синусового ритма.
- Комплексы QRS имеют нерегулярную форму и различную амплитуду, что может свидетельствовать о фибрилляции.

2. Нерегулярность ритма:

- Интервалы между комплексами QRS неравномерные, что указывает на нерегулярный ритм сердца.

3. Изменение амплитуды и формы комплексов QRS:

- Комплексы QRS сильно варьируются по амплитуде и форме, что характерно для фибрилляции предсердий.

4. Низкая амплитуда волн:


- Амплитуда волн неравномерная и часто низкая, что может быть признаком электрической нестабильности.

На основе указанных признаков можно предположить диагноз **фибрилляции предсердий (Atrial Fibrillation, AFib)**. Это состояние характеризуется отсутствием нормального синусового ритма, нерегулярностью сердечных сокращений и изменением амплитуды и формы комплексов QRS.

Диагноз определен неверно

(источник: <http://cardiologspb.ru/>)

Николин К.М. «Синдром сонного апноэ», лекция для врачей)



Посмотри на сигнал ЭКГ. Определи диагноз по этому сигналу ЭКГ и объясни, какие признаки указывают на наличие этого диагноза в данном сигнале.

На предоставленном графике ЭКГ можно наблюдать изменения частоты сердечных сокращений (ЧСС) в течение ночного сна, с частыми эпизодами брадикардии и тахикардии. Вот возможный диагноз и объяснение:

Диагноз:

Синдром обструктивного апноэ сна (ОАС)

Признаки, указывающие на наличие ОАС в данном сигнале:

1. Частые смены эпизодов брадикардии и тахикардии:

- Во время апноэ (периоды, когда дыхательные пути заблокированы), происходит снижение уровня кислорода в крови, что вызывает брадикардию (замедление ЧСС).
- После восстановления дыхания (в конце эпизода апноэ) происходит компенсаторное увеличение ЧСС (тахикардия), чтобы восполнить дефицит кислорода.

2. Нерегулярность ЧСС:

- Наблюдаются резкие изменения в ЧСС, что характерно для пациентов с апноэ сна. Эти изменения связаны с частыми пробуждениями или микро-пробуждениями, которые не позволяют перейти в глубокие стадии сна.

3. Длительные периоды стабильной низкой активности:

- В некоторых частях графика видно длительное снижение активности, что может указывать на длительные эпизоды апноэ, когда сердечная активность значительно замедляется.

Дополнительные признаки:

- **Флуктуации амплитуды сигналов:**
 - Это может быть связано с изменением дыхательных паттернов, особенно при обструктивном апноэ сна, когда дыхательные усилия меняются.

Для точной диагностики необходимы дополнительные данные и анализы, включая полисомнографию, которая является золотым стандартом для диагностики обструктивного апноэ сна.

Диагноз определен верно

(источник: <http://cardiologspb.ru/>)

Николин К.М. «Синдром сонного апноэ»,
лекция для врачей)

- **Выводы:**

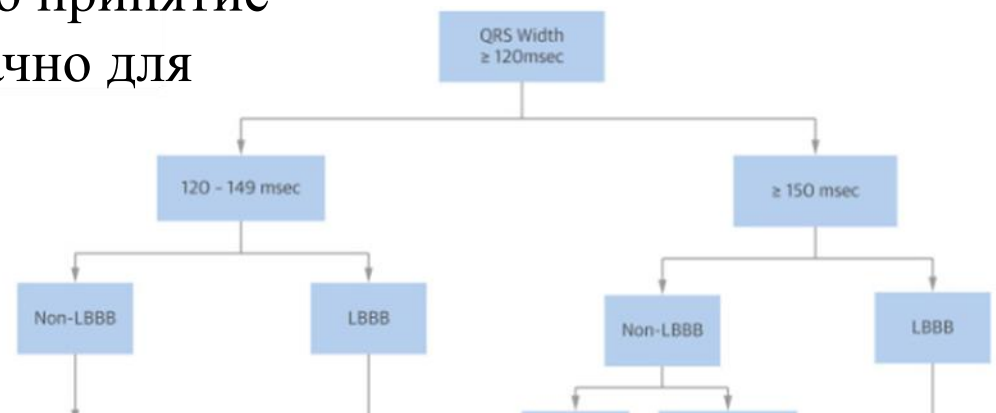
- Хороший результат на некоторых сигналах ЭКГ может объясняться тем, что сеть уже «видела» данные сигналы на этапе обучения или «нашла» их в Интернете (так как у новой модели есть доступ к Интернету);
- Очевидным недостатком использования новой версии ChatGPT является наличие лимитов на количество запросов. Всего в сутки можно подать **3 картинки** с сигналом ЭКГ для анализа (в бесплатной версии);

Итоговая система будет разбита на два модуля:

- **Разметка:** детектирование морфоформ сердечного цикла (где и что в сигнале нашли), включая информацию о типе волны и ее особых точках;
- **Детерминированные правила** вида «если – то», которые по результатам разметки генерируют диагностическое заключение (представляет собой дерево принятия решений).

Достоинство подхода в том, что принятие решений деревом очень прозрачно для человека.

Однако это будет работать только при условии очень хорошей разметки сигнала.



- Предлагается построить разметчик путем целенаправленного обучения трех специализированных подсетей.
- Сначала получить сеть, которая будет «знать» все принципиальные варианты того, как может выглядеть QRS-комплекс. Затем, то же самое для левой части цикла (относительно QRS) и для правой.

В чем преимущество:

- Разбиение задачи на три подзадачи хорошо тем, что для каждой из подзадач получаем относительно небольшую размерность.

Обучение детектора будем проводить в две фазы:

- Предобучение
- Дообучение

1) Предобучение сети произведем на всех собранных неразмеченных данных. Обучать будем любой задаче (например, автокодированию небольших фрагментов ЭКГ, различению ЭКГ и случайного сигнала). Результат этого шага: понижение размерности с устранением шума в сигнале, но с сохранением семантики.

2) При помощи врача отметим в полученном низкоразмерном пространстве кодов области, отвечающие разным морфологиям комплекса.

Фрагмент сигнала фиксированной длины N - это точка в N -мерном пространстве.

Сигнал ЭКГ ограничен диапазоном.




Рис.4. Двумерное многообразие, вложенное в 3-мерное пр-во. Конечно, многообразие, на которое мы попробуем “уложить” ЭКГ, куда более патологично. Оно, например, врядли компактно.

Значит, любой такой сигнал является точкой в N -мерном гиперкубе.

В идеальных условиях сигналы, которые представляют собой одну и ту же морфоформу комплекса, лежат на одном участке многообразия




Рис.5.: Варианты нормы и патологий, имеющие у врачей названия, находятся на многообразии в виде компактов.

Но в реальности будет не совсем так: для конкретной патологии соответствующие ей коды не будут компактом.




Рис.6: В результате предобученного понижения размерности сигнала коды, соответствующие конкретной патологии QRS-комплекса, не образуют компакта

Для решения этой проблемы применим подход переноса знаний.

Добавленный сверху слой будет играть роль отображения, суть которого показана на следующем рисунке:




Рис.7.: Отображение показано красными отрезками, оно переводит коды в др. пространство, где все красные фрагменты собираются в компакт


Таким образом, протокол дообучения новой патологии имеет следующий вид:

1. Даем модели на вход пример QRS этой патологии;
2. Она своим предобученным энкодером генерирует координату данного сигнала на выученном многообразии;
3. Рассматриваем коды из окрестности данных кодов с целью нащупать «красное пятно» из рис.7. На каждую точку во время этого «нащупывания» модель генерирует соответствующий сигнал, а врач отвечает, это все еще данная патология или нет.
4. Эти ответы врача являются обучающим сигналом для отображения с рис.7.


- В результате мы имеем задачу разработки энкодера для понижения размерности сигнала;
- Для того чтобы сделать хороший энкодер, нужно убедиться, что он хорошо кодирует исходное ЭКГ в низкоразмерное пространство признаков;
- Следовательно, для начала следует разработать автоэнкодер (убедившись в его корректности, мы оставим только кодирующую часть для понижения размерности);
- Чтобы избежать проблем со сдвигом сигнала, будем реализовывать сверточный автоэнкодер.

- В качестве данных будем использовать датасет LUDB.
- Поскольку записей в LUDB не так много, но каждая запись содержит 12 отведений, будем обучать автоэнкодер на данных каждого отведения.
- Таким образом, в train set подаются данные всех отведений, нарезанные на кусочки по длине сердечного цикла.


- В реализованном автоэнкодере имеется по 3 сверточных слоя с размером ядра, равным 3, в энкодере и декодере.




- Будем обучать автоэнкодер, используя в качестве функции потерь MSE.
- В результате после обучения на 50 эпохах получаем следующий график потерь:




Практическая задача: результаты




Исходный сигнал




Результат работы автоэнкодера




Практическая задача: результаты



Исходный сигнал



Результат работы автоэнкодера



- Были рассмотрены статьи по обучению на нескольких образцах и выявлены некоторые лайфхаки, которые могут быть использованы при организации обучения в нашем подходе;
- Была протестирована новая сеть ChatGPT-4o;
- В ходе работы был реализован сверточный автоэнкодер, хорошо кодирующий и декодирующий сигналы ЭКГ (включая редкие заболевания) для понижения размерности сигнала.

1. Pałczyński K. et al. Study of the few-shot learning for ECG classification based on the PTB-XL dataset //Sensors. – 2022. – Т. 22. – №. 3. – С. 904. <https://doi.org/10.3390/s22030904>
2. Li Z., Wang H., Liu X. A one-dimensional Siamese few-shot learning approach for ECG classification under limited data //2021 43rd annual international conference of the IEEE engineering in medicine & biology society (EMBC). – IEEE, 2021. – С. 455-458. <https://ieeexplore.ieee.org/document/9630622>
3. Liu T. et al. Few-shot learning for cardiac arrhythmia detection based on electrocardiogram data from wearable devices //Digital Signal Processing. – 2021. – Т. 116. – С. 103094 <https://www.sciencedirect.com/science/article/abs/pii/S1051200421001330>
4. Zhang W. et al. MetaVA: Curriculum meta-learning and pre-fine-tuning of deep neural networks for detecting ventricular arrhythmias based on ECGs //arXiv preprint arXiv:2202.12450. – 2022. <https://doi.org/10.48550/arXiv.2202.12450>
5. Yu H., Guo P., Sano A. Zero-Shot ECG Diagnosis with Large Language Models and Retrieval-Augmented Generation //Machine Learning for Health (ML4H). – PMLR, 2023. – С. 650-663. <https://arxiv.org/pdf/2406.03712>
6. Li C., Denison T., Zhu T. A Survey of Few-Shot Learning for Biomedical Time Series //arXiv preprint arXiv:2405.02485. – 2024. <https://doi.org/10.48550/arXiv.2405.02485>
7. Yildirim O., San Tan R., Acharya U. R. An efficient compression of ECG signals using deep convolutional autoencoders //Cognitive Systems Research. – 2018. – Т. 52. – С. 198-211. <https://doi.org/10.1016/j.cogsys.2018.07.004>