

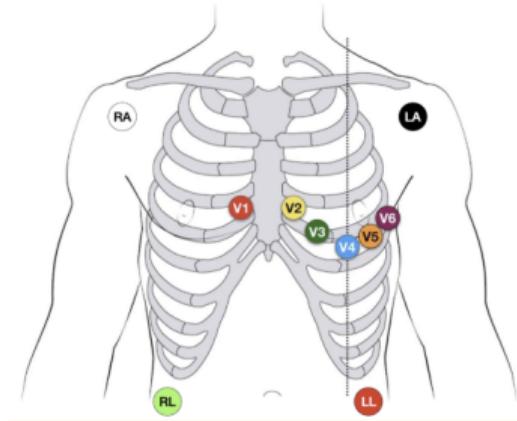
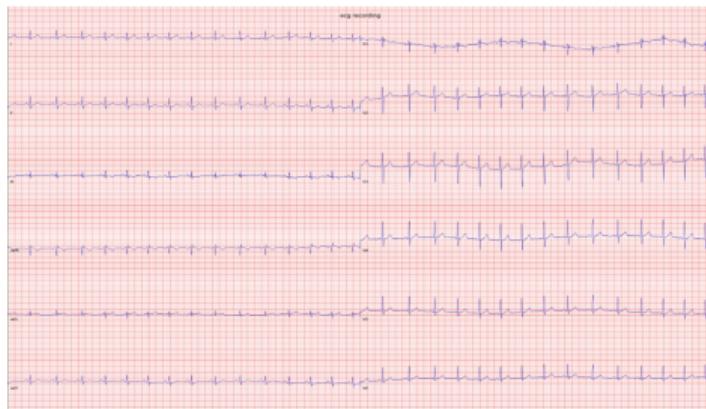
# Медицинские приложения, ЭКГ

Арам Аветисян

5 ноября 2025

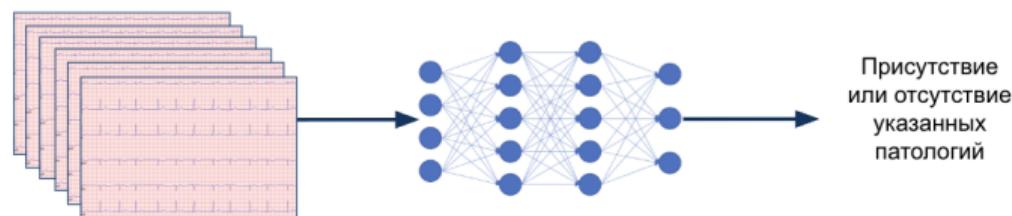
# Что такое ЭКГ?

- Электрокардиография - метод регистрации электрической активности сердца. Это стандартная процедура для оценки состояния сердца
- Изучаются ЭКГ с разным числом каналов (1, 6, 12)
- Анализируется сигнал ЭКГ, а не картинка



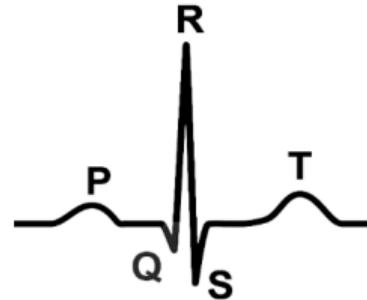
# Какую задачу решаем?

- Вход: временные ряды ЭКГ-сигналов
- Выход: классификация патологий
  - Бинарная классификация (норма/патология)
  - Мультиклассовая классификация (тип аритмии)
  - Мультилейбл классификация (несколько одновременных патологий)



## Подход до нейросетей:

- Извлечение hand-crafted признаков
- Детекция характерных точек (P, QRS, T) и нализ морфологических параметров:
  - $RR_{interval} = t_{R_{n+1}} - t_{R_n}$
  - $QRS_{duration} = t_S - t_Q$
  - $QT_{interval} = t_T - t_Q$



# Доступные данные для обучения

## Закрытые наборы

- **ISP:** >1 млн записей, 12 отведений
- Длина: 6-60 сек, Частота: 500/1000 Гц
- Госпитальные аннотации кардиологов

## Открытые наборы

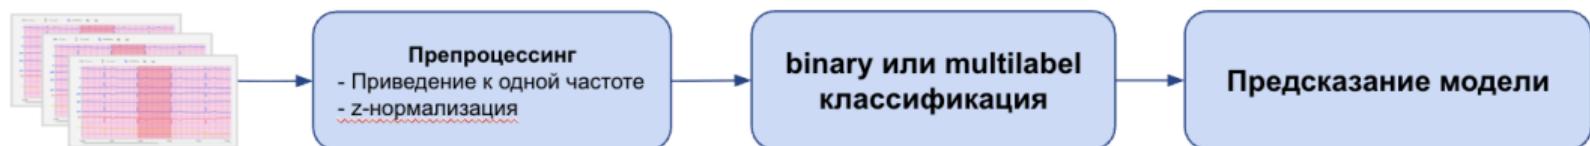
- **PTB-XL:** 22 тыс. записей, 12 отведений
- **Chapman:** 10 тыс. записей, 12 отведений
- **CPSC2018:** 9 тыс. записей, 12 отведений

## Следствие

Появление больших данных сделало возможным применение глубокого обучения

# Стандартный алгоритм действий

- Предобработка ЭКГ:
  - Ресемплинг к единой частоте (например, 500 Гц)
  - Нормализация:  $x_{norm} = \frac{x-\mu}{\sigma}$
  - Фильтрация низкочастотных шумов
- Выбор архитектуры нейросети. ЭКГ может работать с разными типами: сверточные, рекуррентные, трансформеры



# Результаты работы моделей

- Метрики качества классификации:

- Чувствительность (Recall):

$$Se = \frac{TP}{TP + FN}$$

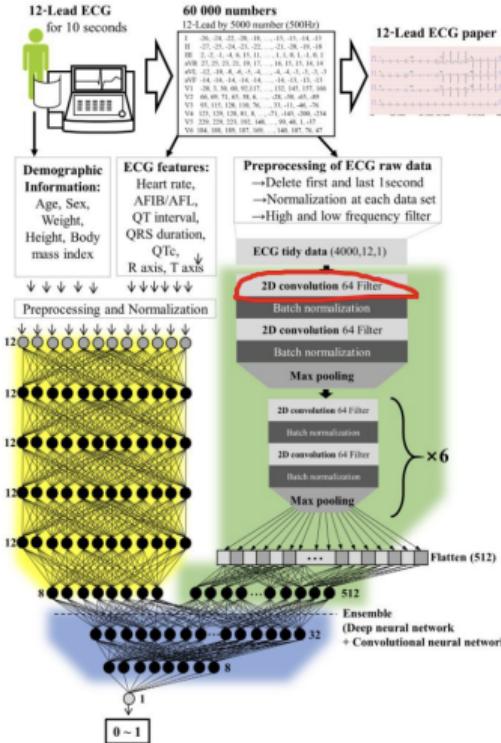
- Специфичность:  $Sp = \frac{TN}{TN + FP}$

- G-mean:  $G = \sqrt{Se \times Sp}$

Патология	Sensitivity	Specificity	G-mean
Atrial Fibrillation	0.981	0.975	0.978
Ventricular Premature Complexes	0.958	0.890	0.923
Sinus Tachycardia	0.912	0.939	0.926
Sinus Bradycardia	0.918	0.977	0.947
First Degree AV Block	0.921	0.923	0.922
Incomplete Right Bundle-Branch Block	0.825	0.936	0.878
Complete Right Bundle-Branch Block	0.963	0.980	0.972
Complete Left Bundle-Branch Block	0.965	0.970	0.967
Supraventricular Premature Complexes	0.930	0.861	0.894
Left-axis Deviation	0.877	0.952	0.914
Right-axis deviation	0.939	0.960	0.949
Left Anterior Fascicular Block	0.890	0.870	0.880

# Метаданные

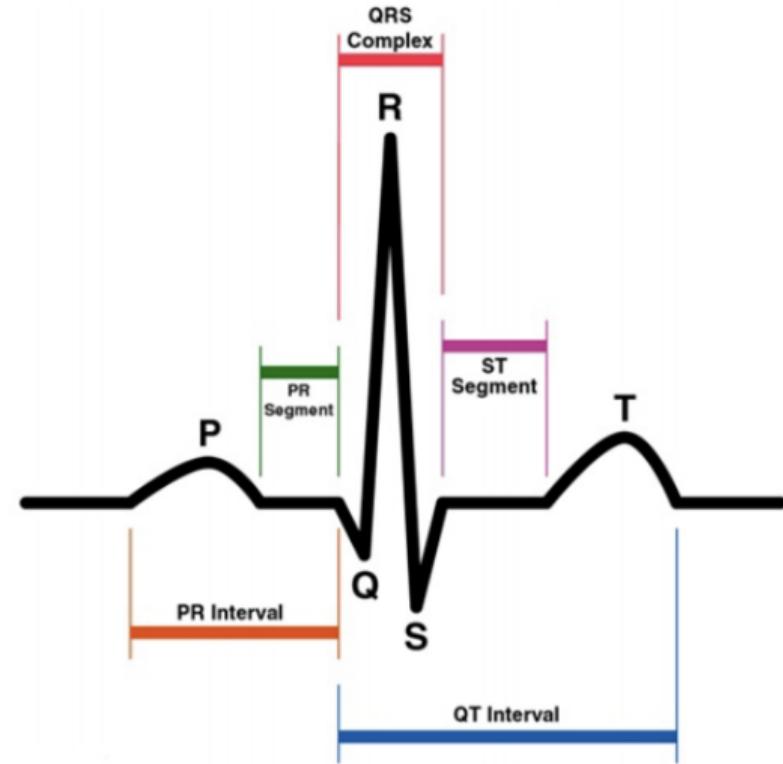
- Для улучшения качества предсказания можно добавить метаданные пациента (ЭКГ записи или других медицинских анализов пациента)
- В большинстве случаев в наборах данных мало метаданных



- **Врачам важна интерпретируемость** — необходимо понимать, на основе чего модель принимает решения
- **Два основных подхода:**
  - **Сегментация комплексов** — вычисление параметров ЭКГ (интервалы, амплитуды)
  - **Визуализация** — выделение важных участков сигнала для классификации

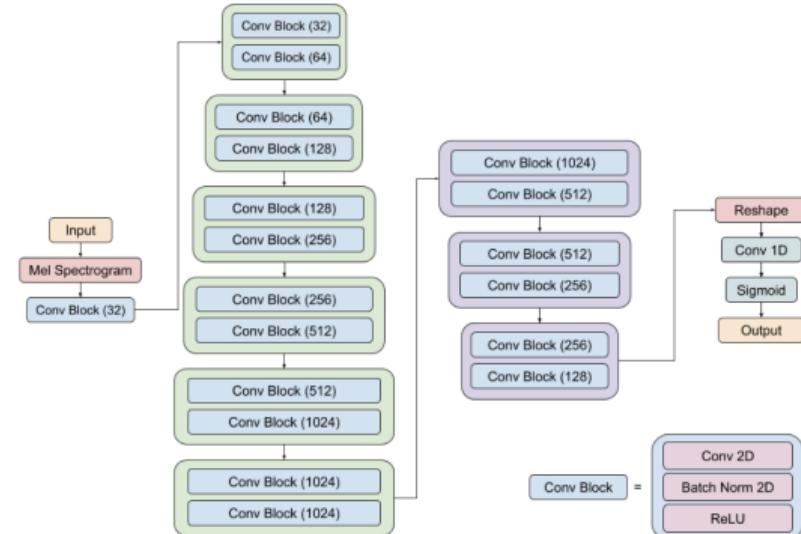
# Интерпретируемость: сегментация комплексов

- **Задача:** найти положения пиков, начал и концов интервалов:
  - Комплекс QRS
  - Волна P
  - Волна T
- **Первые методы:** "математические" подходы
  - Фильтрация сигнала
  - Поиск локальных экстремумов
- **Проблема:** плохая точность для слабо выраженных волн (P, T)



# Интерпретируемость: сегментация комплексов

- **Датасеты:** ограниченное количество аннотированных данных (разетка сложнее классификации)
  - LUDB, QTDB, ISPdeli
- **Архитектуры:** Encoder-decoder подходы
- **Вход:** исходная ЭКГ запись
- **Выход:** вектор, определяющий координаты волн P, T и зубцов QRS



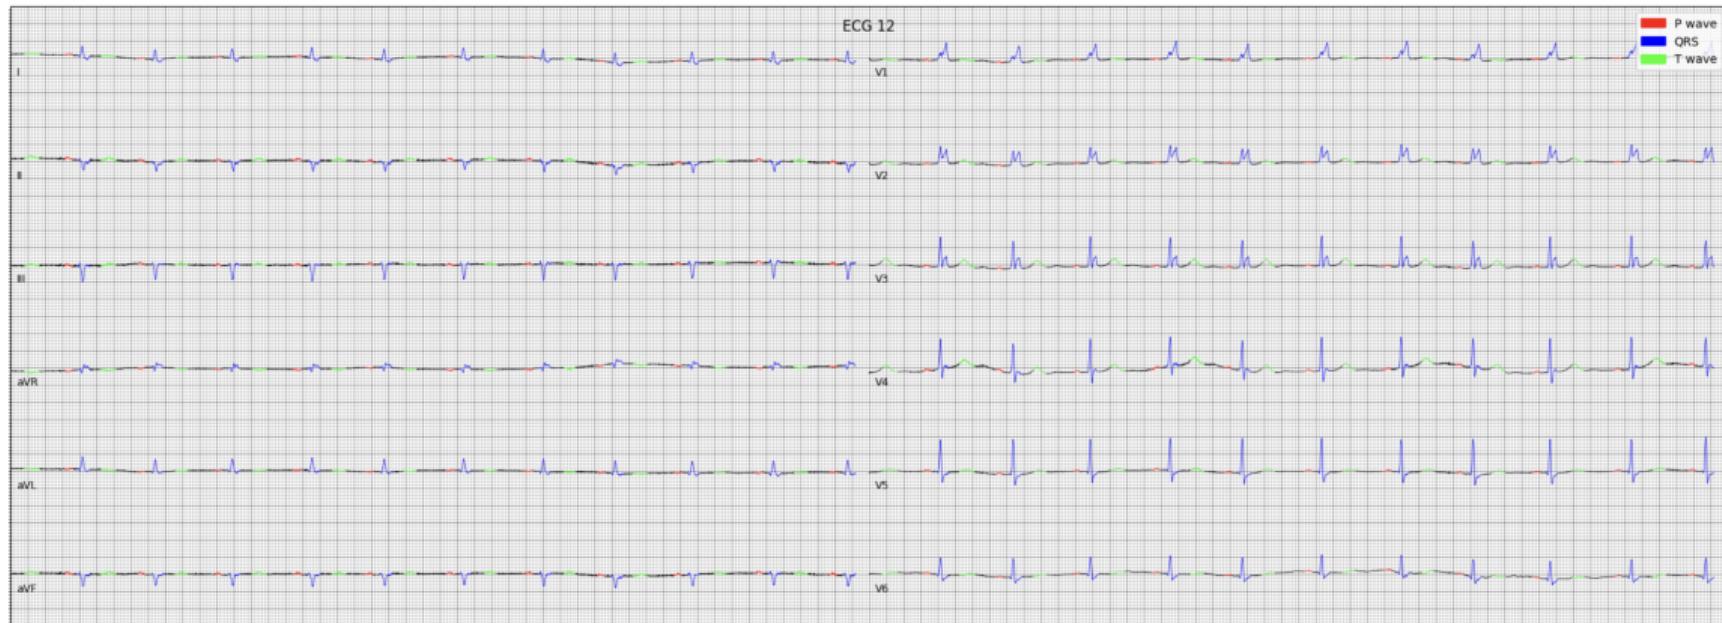
- Определяемые точки:
  - P\_onset, P\_offset, QRS\_onset, QRS\_offset, T\_onset, T\_offset
- Критерии оценки:
  - **TP**: предсказания в пределах 150 мс от истинных точек
  - **FP**: предсказания без соответствующих истинных точек
  - **FN**: истинные точки вне окна допуска
  - Окно допуска: 150 мс
- Метрики качества:
  - Чувствительность:  $Se = \frac{TP}{TP+FN}$
  - Precision:  $PPV = \frac{TP}{TP+FP}$
  - F1-score:  $F1 = 2 \cdot \frac{PPV \cdot Se}{PPV + Se}$
  - Ошибка: средняя и std в мс
  - Ключевая метрика: F1-score

# Оценка качества сегментации

		<b>P on</b>	<b>P off</b>	<b>QRS on</b>	<b>QRS off</b>	<b>T on</b>	<b>T off</b>
Moskalenko et al. [9]	<i>Se</i>	0.962	0.962	0.999	0.999	0.972	0.972
	<i>PPV</i>	0.981	0.981	0.992	0.992	0.984	0.984
	<i>F1-score</i>	0.971	0.971	0.996	0.996	0.978	0.978
	$\mu \pm \sigma$	$-0.0 \pm 7.9$	$0.7 \pm 9.0$	$-0.3 \pm 6.6$	$-0.5 \pm 8.6$	$-3.2 \pm 20.7$	$0.4 \pm 15.0$
Liang et al. [10]	<i>Se</i>	0.952	0.953	0.997	0.996	0.994	0.990
	<i>PPV</i>	0.952	0.953	0.988	0.987	0.967	0.963
	<i>F1-score</i>	0.952	0.953	0.992	0.991	0.981	0.976
	$\mu \pm \sigma$	$-2.0 \pm 16.5$	$0.5 \pm 16.1$	$0.7 \pm 7.4$	$0.0 \pm 9.2$	$-3.1 \pm 23.1$	$0.0 \pm 18.1$
Chen et al. [12]	<i>Se</i>	0.964	0.964	0.977	0.977	0.968	0.968
	<i>PPV</i>	0.986	0.986	0.983	0.983	0.976	0.976
	<i>F1-score</i>	<b>0.975</b>	0.975	0.980	0.980	0.972	0.972
	$\mu \pm \sigma$	$-0.2 \pm 5.4$	$0.0 \pm 2.7$	$0.2 \pm 9.6$	$-0.2 \pm 10.2$	$-0.6 \pm 4.8$	$0.1 \pm 4.6$
ECG-CODE (our work)	<i>Se</i>	0.960	0.962	0.996	0.996	0.986	0.983
	<i>PPV</i>	0.978	0.981	0.998	0.998	0.980	0.977
	<i>F1-score</i>	0.969	0.971	0.997	0.997	0.983	0.980
	$\mu \pm \sigma$	$-3.1 \pm 16.4$	$-5.1 \pm 14.2$	$0.2 \pm 9.7$	$0.4 \pm 11.3$	$-3.0 \pm 27.3$	$-0.4 \pm 26.4$

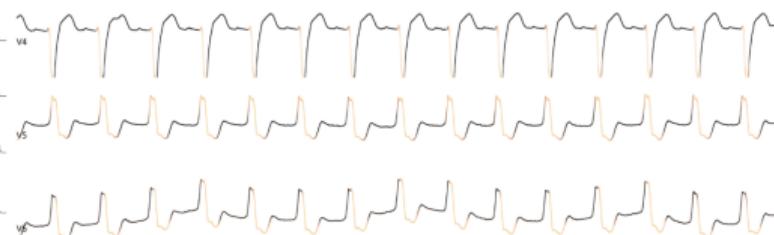
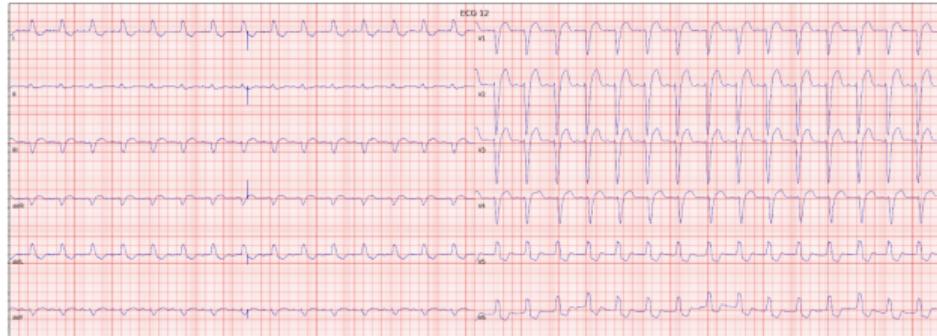
# Пример визуализации

## Пример сегментации ЭКГ записи



# Пример визуализации

## Пример визуализации для интерпретации ЭКГ моделей



- **Проблема:** Разметка медицинских данных требует значительных ресурсов и времени экспертов-кардиологов
- **Решение:** Получить неразмеченные 12-канальные ЭКГ проще. Использование неразмеченных 12-канальных ЭКГ записей для предобучения моделей

# Как можно решать эту задачу?

**Проблема:** Разметка медицинских данных требует значительных ресурсов и времени экспертов-кардиологов

**Решение:** Получить неразмеченные 12-канальные ЭКГ проще. Использование неразмеченных 12-канальных ЭКГ записей для предобучения моделей

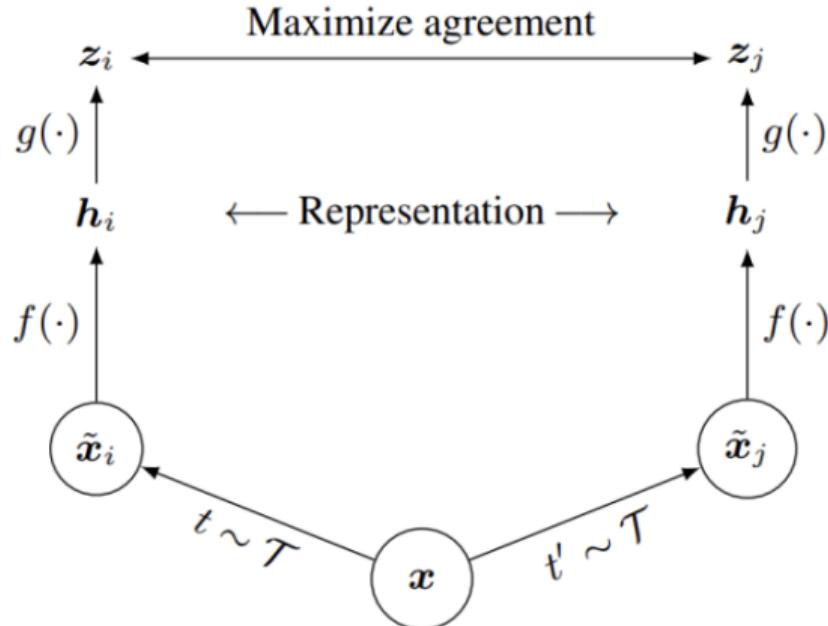
Мы придумываем задачу на этих данных, которую мы можем решить:

- Восстановление маскированных данных: случайно "маскируем" (обнуляем или заменяем шумом) значительный отрезок 12-канальной ЭКГ. Задача модели — восстановить исходный сигнал на замаскированном участке.
- Контрастное обучение: Идея: "Схожие" примеры должны быть ближе в пространстве признаков, а "непохожие" — дальше.

- **Автоэнкодеры + шум**
  - Вход: зашумленный сигнал
  - Задача: восстановить исходный
- **Маскирование сигнала**
  - Маскирование участков ЭКГ
  - Задача: восстановить пропуски
- **Перемешивание сегментов**
  - Нарезка и перестановка частей
  - Задача: восстановить порядок

- Создание "позитивных" пар: Берем якорной пример (anchor). Создаем его модифицированную копию (positive) с помощью аугментаций. Они должны считаться "похожими".
- "Негативные" примеры: Все остальные примеры в батче считаются "непохожими" (negatives).
- Модель (энкодер) настраивается так, чтобы векторы якоря и позитива были близки в пространстве признаков, а векторы якоря и негативов - далеки.

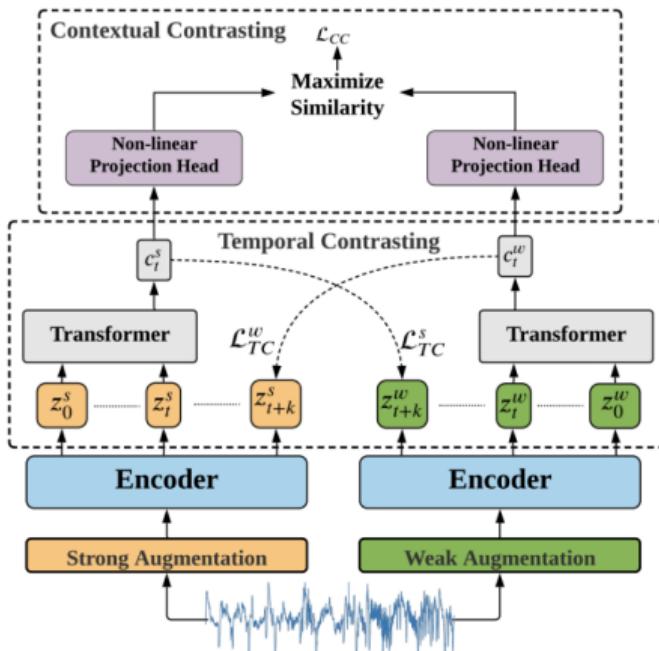
Примеры методов: SimCLR, TS-TCC, TF-C, PCL



## Simple Framework for Contrastive Learning

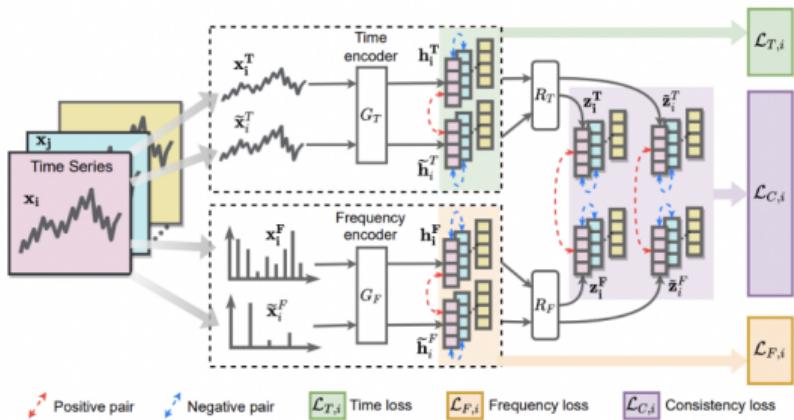
- Две аугментации одного примера
- Encoder + Projection head
- Функция потерь NT-Xent:

$$\mathcal{L}_{i,j} = -\log \frac{\exp(\text{sim}(z_i, z_j)/\tau)}{\sum_{k=1}^{2N} \mathbb{1}_{k \neq i} \exp(\text{sim}(z_i, z_k)/\tau)}$$



## Time Series Temporal Contrastive Coding

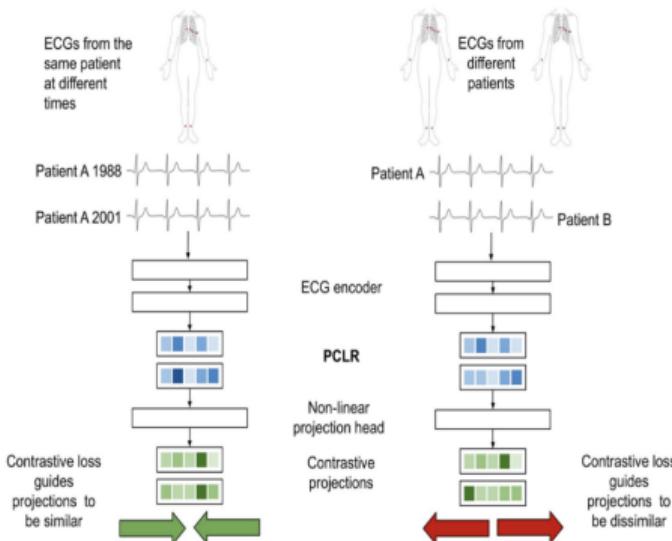
- Сильные и слабые аугментации
- Два вида контрастных потерь:
  - Temporal Contrastive Loss
  - Context Contrastive Loss
- Особенности:
  - Учет временной структуры
  - Разные уровни аугментаций



## Time-Frequency Consistency

- **Домены:** временной и частотный
- Контраст между представлениями:
  - Временное представление
  - Частотное представление (спектрограмма)
- **Преимущества:**
  - Использует оба представления сигнала
  - Учет спектральных характеристик

# Patient Contrastive Learning



- Идея: Записи от одного пациента считаются позитивными парами

## Парная функция потерь

$$\ell_{i,j} = -\log \frac{\exp[\text{sim}(z_i, z_j)/\tau]}{\sum_{k=1}^{2N} \mathbb{1}_{k \neq i} \exp[\text{sim}(z_i, z_k)/\tau]}$$

## Функция потерь для батча

$$\mathcal{L}_{batch} = \sum_{p=1}^N \ell_{p_1, p_2}$$

# 1-канальные ЭКГ

**1-канальные ЭКГ** снимают информацию с двух электродов на руках

**1-канальные ЭКГ** гораздо проще снять, чем 12-канальную ЭКГ

По **1-канальным ЭКГ** тоже можно сказать о ряде патологий



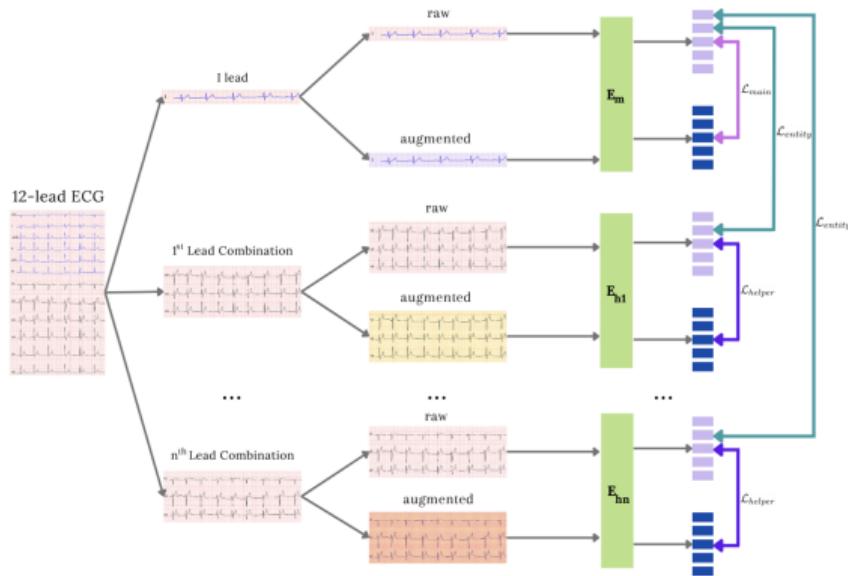
# 1-канальные ЭКГ

**Проблема:** 1-канальные ЭКГ содержат меньше информации чем 12-канальные

**Наблюдение:** 1-канальные ЭКГ повторяют первое отведение 12-канальной ЭКГ

**Идея:** Использовать 12-канальные ЭКГ для предобучения моделей и использовать модели в анализе 1-канальных ЭКГ

# Контрастное обучение для переноса знаний

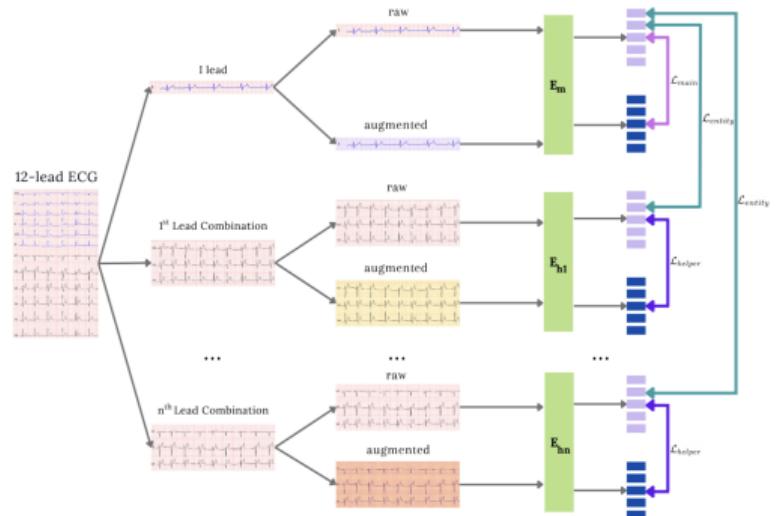


Делим 12-канальную ЭКГ на несколько частей по несколько отведений в каждой. В первой основной части оставляем первое отведение

**Функции потерь:**

- $\mathcal{L}_{main} = \mathcal{L}_{NTXent}(h_I^{(k_1)}, h_m^{(k_1)})$
- $\mathcal{L}_{helper}^i = \mathcal{L}_{NTXent}(h_I^{(k_i)}, h_m^{(k_i)}), \quad i = \overline{2, n}$
- $\mathcal{L}_{entity}^j = \mathcal{L}_{NTXent}(h_I^{(k_1)}, h_m^{(k_j)}), j = \overline{2, n}$

# Контрастное обучение для переноса знаний



Делим 12-канальную ЭКГ на несколько частей по  
несколько отведений в каждой. В первой  
основной части оставляем первое отведение

$$L = \lambda_1 \cdot \mathcal{L}_{main} + \sum_{i=2}^n \lambda_i \cdot \mathcal{L}_{helper}^i + \sum_{j=2}^n \eta_j \cdot \mathcal{L}_{entity}^j$$

# Федеративное обучение

- Медицинские данные зачастую являются персональной информацией пациента, поэтому их централизованное хранение невозможно.

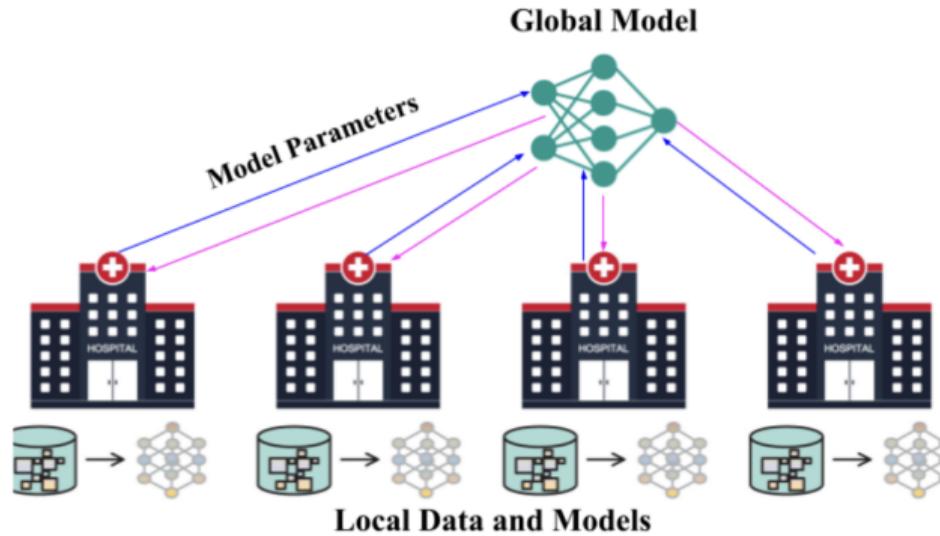


Figure: Сценарий федеративного обучения в больницах

## Формальная постановка

- Веса глобальной модели на раунде  $t$ :  $x^t$
- Веса локальной модели клиента  $i$  на раунде  $t$ :  $x_i^t$
- Лосс-функция клиента  $i$ :  $f_i(\cdot)$
- Глобальный objective-function:

$$\min_x f(x) = \min_x \sum_i^N f_i(x)$$

- Каждый раунд выбираем  $M$  из  $N$  клиентов (FedAvg)
- Агрегация на сервере (FedAvg)

$$x^{t+1} = \frac{1}{M} \sum_{i=1}^M x_i^{t+1}$$

- Возьмем часть большого набора данных ISP и поделим его на 50 частей - 50 клиентов федеративного обучения
- Обучим FedAvg решать задачу классификации патологий в сценарии федеративного обучения: с 1, 10 и 50 клиентами
- Протестируем обученную модель на тестовой выборке ISP и на отдельном наборе данных PTB-XL

# Результаты на тестовых данных

## Электрокардиография (G-mean)

	1AVB	PVC	AFIB	CLBBB	LAFB	CRBBB
1 client	0.482	0.547	0.779	0.879	0.685	0.000
10 clients	0.861	<b>0.932</b>	0.941	0.947	0.761	<b>0.954</b>
50 clients	<b>0.891</b>	0.903	<b>0.961</b>	<b>0.962</b>	<b>0.812</b>	0.923
centralized	0.896	0.934	0.958	0.956	0.823	0.950

## Валидация на PTB-XL (G-mean)

	1AVB	PVC	AFIB	CLBBB	LAFB	CRBBB
1 client	0.000	0.488	0.000	0.682	0.671	0.000
50 clients	0.797	0.909	0.925	0.989	0.891	0.944

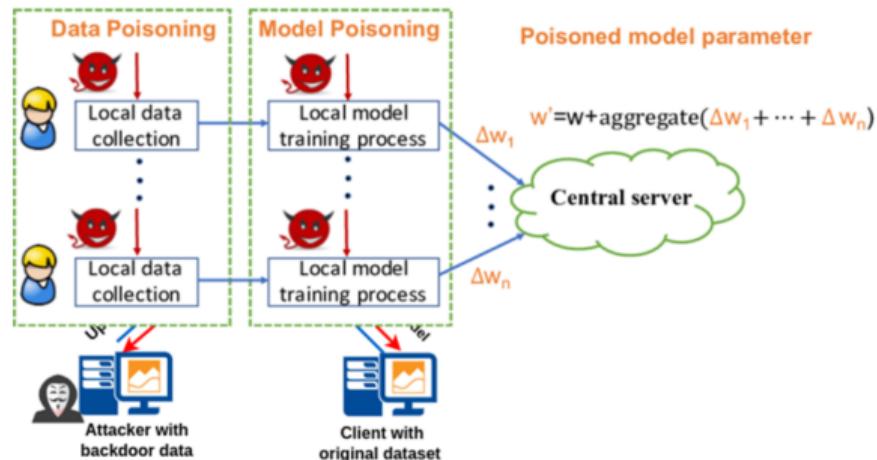
- Каждый клиент содержит сотни примеров ЭКГ (месяцы реального сбора данных)

# Какие проблемы могут возникнуть в задаче федеративного в ЭКГ

- **Распределение данных** — например, разные классы патологий распределены неравномерно между клиентами
- **Приватность** — защита персональных медицинских данных пациентов
- **Коммуникационные затраты** — ограничения пропускной способности в реальных медицинских системах
- **Византийские атаки** — атаки на модели

# Византийские атаки

- Византийцы – клиенты, которые как-то пытаются испортить наше обучение
- Они могут отправлять случайные градиенты вместо нормальных, менять метки данных на противоположные в обучающей выборке, да и в целом делать любые действия для ухудшения глобальной модели.



# Как с ними бороться

- При агрегации на сервере

$$x^{t+1} = \sum_{i=1}^M \omega_i \cdot x_i^{t+1}$$

мы можем подбирать веса  $\omega_i$  (вместо  $\frac{1}{M}$ ) так, чтобы атакующие клиенты вносили лишь небольшой (или нулевой) вклад в общую глобальную модель.

- Давайте предположим, что на сервере есть небольшая, чистая выборка данных
- Тогда, если мы будем смотреть качество полученной модели клиента на этой выборке, то сможем делать выводы о том, византийцев клиент или нет
- Это основа метода BANT (Byzant ANTidote):

$$w_i^t = \frac{\hat{f}(x^t) - \hat{f}(x_i^t)}{\sum_i [\hat{f}(x^t) - \hat{f}(x_i^t)]}$$

- Где  $\hat{f}$  – лосс на чистой серверной выборке (trust loss)

# Другие направления исследований

- Персонализация под пациента для определения изменений в динамике
- Определение по ЭКГ болезней, которые определяются по другим анализам
- Генерация ЭКГ
- Анализ шума на ЭКГ

