

УДК 004.89

Использование сиамских нейронных сетей для выявления кратковременных изменений ЭКГ в жизнеугрожающих случаях

Улизько М.В. (ИТМО), Голубев А.А. (ИТМО)

Научный руководитель - Гусарова Н.Ф. (ИТМО)

Введение. По статистике World Health Organization, более 4,3 миллиона (48%) смертей в Европе связаны с заболеваниями системы кровообращения. Среди всех сердечно-сосудистых заболеваний острый инфаркт миокарда (ОИМ) является ведущей причиной смертности. ОИМ традиционно классифицируют на: инфаркт миокарда с подъемом сегмента ST (ИМпST); инфаркт миокарда без подъема сегмента ST (ИМбпST) на основании характеристик ЭКГ. Пациенты с ИМпST страдают от более высокого риска краткосрочной смертности. Для контроля таких заболеваний используют устройство мониторинга. Оно состоит из одноразового сенсорного пластыря с внешней батареей и электронного сенсорного модуля. Датчик собирает непрерывную кривую ЭКГ, сопротивление кожи, температуру кожи, а также информацию об активности и позе [1].

В рамках исследования требуется разработать обработчик данных ЭКГ, идентифицирующий кратковременные изменения ЭКГ в опасных для жизни случаях с использованием сиамских сетей. Более того, необходимо применить методы ХАИ для обеспечения соответствия результатов прогнозирования клинико-диагностическому опыту врачей-кардиологов.

Основная часть. Нашим решением является модель искусственного интеллекта, основным результатом работы которой является классификация входного сигнала ЭКГ как здорового либо нездорового с применением подхода Few-Shot Learning (сравнение с небольшим количеством «образцовых» данных). Его основными частями являются: модуль вычисления эмбедингов и KNN-классификатор. Архитектура данной сети состоит из сверточного слоя, за которым следуют 4 пропускных блока с двумя сверточными слоями на блок. Выходные данные последнего блока поступают в полносвязный слой с функцией активации гиперболического тангенса на выходе. Выходные данные каждого сверточного слоя масштабируются повторно с использованием пакетной нормализации и подаются на вход слоя функции активации GELU. Dropout слой применяется после функции активации. Модулем вычисления эмбедингов является 1D-сверточная нейронная сеть, обученная с применением подхода сиамских сетей. Данный подход предполагает использование двух идентичных нейронных сетей, которые обучаются на одних и тех же данных и имеют общие веса. При этом выходы нейронных сетей сравниваются на основе метрики расстояния – чем меньше расстояние, тем более схожи входные образы.

Исходным набором данных был РТВ-XL, который представляет собой набор данных из 21 799 клинических ЭКГ от 18 869 пациентов продолжительностью 10 секунд. Перед нормализацией данных весь датасет был разделен на тренировочную, валидационную и тестовую выборку. Как было отмечено ранее, KNN-классификатор настраивается на основе небольшого количества образцовых здоровых и нездоровых ЭКГ. Наша модель

поддерживает указание класса отклонения ЭКГ для нездоровых ЭКГ, из которого случайным образом будут выбраны данные: изменения в ST/T сегменте, инфаркт миокарда, гипертрофия, нарушение проводимости, все возможные классы.

Для реализации возможности выделения зон ЭКГ, на которые сеть обращала наибольшее внимание был реализован метод визуализации Grad-CAM [2]. Принцип работы Grad-CAM заключается в том, что он использует градиенты определенного сверточного слоя нейронной сети по отношению к активациям этого сверточного слоя, чтобы определить, какие области ЭКГ были наиболее активны при принятии решения. Затем эти градиенты усредняются по всем каналам сверточного слоя, для получения карты активаций, которая демонстрирует, какие области ЭКГ были наиболее значимы для принятия решения. Поскольку модуль выделения эмбедингов был обучен с применением подхода сиамских сетей, который подразумевает сравнение близости двух векторов, то для захвата градиентов и активаций сверточного слоя данной нейронной сети необходимо пропустить через нее 2 ЭКГ: входную и любую другую противоположного класса, после этого рассчитать расстояние между полученными результатами. В итоге, мы сможем увидеть те участки ЭКГ, на которые сеть обращала внимание и которые помогли найти различия между двумя сигналами.

Выводы. Для решения поставленной задачи уже были предложены альтернативные подходы. Так, Junjiang Zhu, Jintao Lv, и Dongdong Kong в своей статье “CNN-FWS: A Model for the Diagnosis of Normal and Abnormal ECG with Feature Adaptive” [3]. предлагают CNN-FWS, которая сочетает в себе три сверточные нейронные сети (CNN) и рекурсивное исключение признаков на основе весов признаков (FW-RFE), которое диагностирует аномальную и нормальную ЭКГ. Результаты эксперимента, проходившем на датасете PTB-XL показывают, что показатель F1-меры CNN-FWS составляет 0,902. В то же время, показатель F1-меры нашей модели варьируется, в зависимости от ситуации (от выбранного класса болезни). Так при сравнении со всеми классами показатель достигает 0.844, однако для отдельно взятых классов датасета показатели выше: 0.924, 0.916, 0.916, 0.934 соответственно для ST, MI, HYP, CD, что является выше заявленных показателей альтернативы.

Список использованных источников:

1. World Health Organization: WHO. (2019). Cardiovascular diseases. www.who.int/health-topics/cardiovascular-diseases#tab=tab_1
2. Keras documentation: Grad-CAM class activation visualization. [online] [keras.io/https://keras.io/examples/vision/grad_cam/](https://keras.io/examples/vision/grad_cam/)
3. Zhu, J., Lv, J., & Kong, D. (2022). CNN-FWS: A Model for the Diagnosis of Normal and Abnormal ECG with Feature Adaptive. Entropy (Basel, Switzerland), 24(4). <https://doi.org/10.3390/e24040471>