

Алгоритм косвенного измерения артериального давления по сигналам фотоплетизмограммы и ЭКГ

Н. О. Антипов¹, А. Н. Калиниченко²

Санкт-Петербургский государственный электротехнический университет

«ЛЭТИ» им. В.И. Ульянова (Ленина)

¹jobber1994@mail.ru, ²ank-bs@yandex.ru

Аннотация. Рассмотрен алгоритм оценки артериального давления человека с использованием сигналов ЭКГ и фотоплетизмограммы. Предсказание значений систолического и диастолического давления осуществлялось с использованием методов машинного обучения.

Ключевые слова: оценка артериального давления, электрокардиограмма, фотоплетизмограмма, машинное обучение

I. ВВЕДЕНИЕ

В настоящее время общепринятым для регистрации артериального давления (АД) считается манжетный метод, поскольку он является наиболее доступным. Однако данный метод имеет ряд ограничений и неудобств при использовании. Для устранения этих недостатков предпринимаются многочисленные исследования, направленные на создание достоверного алгоритма косвенной оценки АД человека. При этом наибольшее распространение получили подходы, основанные на анализе сигналов фотоплетизмограммы (ФПГ) [1] и электрокардиограммы, а также их комбинации. Достаточно часто в качестве устройств регистрации используются телемедицинские устройства, такие, например, как smart-часы [2]. В данном исследовании использовались данные, зарегистрированные с помощью портативный кардиомонитор CardioQvark [3]. Поскольку регистрация сигналов с помощью подобных устройств может происходить в неоптимальной для диагностики обстановке, получаемые сигналы могут иметь высокий уровень помех, что существенно может затруднить или сделать невозможным использования подобных данных для анализа. Одной из целей работы было создание алгоритма очистки сигнала для обеспечения возможности последующего использования в алгоритмах машинного обучения (МО), которые часто используются в безманжетных методах косвенной оценки АД [4, 5]. Проблемой использования алгоритмов МО является их чувствительность к объему выборки, так как это сказывается как на эффективности обучения модели, так и на объективности результата.

В настоящей работе использовались данные только одного пациента, которые были получены в неблагоприятных для регистрации условиях. Выборка состояла из 400 сигналов ЭКГ и ФПГ, в итоговую выборку попало 290 записей пригодных для использования для обучения моделей МО. В своей работе мы использовали несколько моделей – полностью связная нейронная сеть прямого распространения, сверточная нейронная сеть и ансамбль из этих моделей.

Работа выполнена при финансовой поддержке программы стратегического академического лидерства «Приоритет-2030».

II. МЕТОДОЛОГИЯ

В работе использовались два типа сигналов – ЭКГ и фотоплетизмограмма. Исходные сигналы имели высокий уровень шумов, сигнал ФПГ имел сильное плавание нулевой линии. Для устранения помех в сигналах был использован алгоритм очистки сигнала и отбора экземпляров сердечных циклов для использования в искусственных нейронных сетях (ИНС).

A. Предварительная обработка

Для устранения помех использовался фильтр нижних частот (ФНЧ), для устранения сетевой помехи сигнал ФПГ был прорежен до частоты 50 Гц (рис. 1).




Рис. 1. Анализируемые сигналы: ЭКГ (верхний график), а также сигналы ФПГ до и после фильтрации (средний и нижний графики)

Для выделения кардиоциклов использовался алгоритм Пана-Томпкинса [6]. Для восстановления нулевой линии сигнала ФПГ использовался метод кубической сплайн-интерполяции. В качестве узлов интерполяции использовались локальные минимумы каждой из волн. В результате вычитания сплайна получается сигнал без плавания нулевой линии (рис. 2).




Рис. 2. Результаты spline-интерполяции: исходный сигнал ФПГ (верхний график), рассчитанный кубический сплайн (средний график), сигнал ФПГ после вычитания сплайна (нижний график)

Для выбора наилучших волн из сигналов, которые в дальнейшем будут применены для обучения ИНС, рассчитывался коэффициент корреляции волн между собой, и строилась корреляционная матрица. Волны, имеющие высокую степень коррелированности, отбиралась для дальнейшего использования, пороговое значение коэффициента корреляции составляло 0,85, волны, не прошедшие данный порог из-за помех или ошибок, исключались из анализа.

В. Модель предсказания артериального давления

Для создания моделей предсказания использовался фреймворк Keras на языке Python. Было создано две модели предсказания – полносвязная сеть прямого распространения, в которой используется набор информативных признаков, коррелирующих с давлением, для исследуемого пациента, и модель сверточной нейронной сети. Каждая из моделей имеет свои преимущества и недостатки в косвенной оценке АД, так сверточная нейронная сеть имеет большую ориентированность на локальные особенности сигнала, используя автоматическое выделение информативных параметров, тогда как полносвязная ИНС оценивает более общие характеристики сигнала.

Для полносвязной ИНС была создана выборка, с использованием 20 различных признаков. Каждый из признаков исследовался на информативность, устойчивость и коррелированность с другими признаками. Также была проведена проверка на комбинаторную эффективность различных групп признаков посредством регрессионного анализа в среде MATLAB.

Исходя из всех вышперечисленных исследований, были отобраны 9 признаков, продемонстрировавших наилучшую информативность. Список отобранных признаков приведен ниже:

- СКО амплитуды цикла ФПГ;
- ширина волны;
- отношение максимальных пиков первой и второй производных;
- отношение минимальных пиков первой и второй производных;
- амплитуда пиков первой производной;
- амплитуда пиков второй производной;
- RR интервал;
- амплитуда систолических пиков;
- амплитуда максимального пика первой производной.

В качестве входных данных для сверточной ИНС использовались отобранные очищенные от помех волны с высокой степенью корреляции. Для анализа сигналов формировалось окно свертки, постепенно уменьшающееся в размере по мере прохождения слоев, что приводило к отбору наиболее информативных признаков.

Модель ансамбля использует лучшие подобранные весовые коэффициенты из первых двух моделей, выходные данные которых поступают на обобщающий

слой сети, где формируется итоговый ответ ансамбля. На рис. 3 приведена структурная схема ансамбля.




Рис. 3. Структурная схема ансамбля моделей

ТАБЛИЦА I ПАРАМЕТРЫ МОДЕЛЕЙ

Характеристики модели		
Наименование характеристики	Полносвязная ИНС	Сверточная ИНС
Размер модели	2 – скрытых слоя, 1 – прореживающий, 1 – регрессионный слой	3 – сверточных слоя, 3 прореживающих слоя, 1 регрессионный слой.
Прореживающие слои	DropOut слой (коэффициент прореживания 0,8)	MaxPool слой
Размеры окна свертки	Не использовалось	Окна свертки: 100%, 10%, 1%
Регуляризация	L1 и L2 регуляризации	L1-L2, L2 регуляризации
Нормирование	Применялось	Не применялось

Для предотвращения переобучения, связанного с относительно небольшим объемом обучающей выборки, были выбраны варианты конфигурации с относительно небольшим числом слоев. Помимо этого, применялись различные виды регуляризации и прореживания для устранения паразитных связей между нейронами и слоями.

III. РЕЗУЛЬТАТЫ

Для оценки результатов и эффективности модели в качестве метрики использовалась средняя абсолютная ошибка, для оценки функции потерь использовалась среднеквадратическая ошибка. Стоит отметить особенности полученных результатов для каждой из моделей. Предсказания, полученные от полносвязной ИНС, имеют малую степень рассеяния и группируются вокруг среднего значения, в случае же сверточной ИНС результаты имеют большую степень рассеяния и модель способна предсказывать выпадающие значения, которые находятся далеко от среднего. Предсказания, полученные от ансамбля моделей, имеют наименьшую среднюю абсолютную ошибку из-за того, что данный подход к созданию модели совмещает лучшие качества каждой из них. В табл. II представлены результаты, полученные для каждой из моделей.

ТАБЛИЦА II РЕЗУЛЬТАТЫ ПРЕДСКАЗАНИЯ ДЛЯ КАЖДОЙ ИЗ МОДЕЛЕЙ

Наименование выборки	Средняя абсолютная ошибка, мм. рт. ст.	Средняя абсолютная ошибка, %
<i>Модель сверточной нейронной сети</i>		
Обучающая	9,1	9,63
Валидационная	9,65	9,94
Тестовая	10,35	10,66
<i>Модель полносвязной нейронной сети</i>		
Обучающая	5,37	5,75
Валидационная	6,6	7,03
Тестовая	8	8,33
<i>Ансамбль моделей</i>		
Тестовая	7,3	7,77

Как показало экспериментальное исследование алгоритма, наиболее существенные ошибки предсказания величин артериального давления наблюдаются в ситуациях, когда истинные значения заметно отличаются от средних. Это связано в первую очередь с неуравновешенностью выборки, где преобладают образцы со значениями давления, концентрирующимися вокруг наиболее часто встречающихся средних. Данная проблема могла бы быть устранена за счет набора более представительной обучающей выборки.

Были также исследованы требования к минимально необходимому объему обучающей выборки. На рис. 4 представлена зависимость средней ошибки от числа образцов в обучающей выборке. Из графика можно видеть, что для получения минимальных значений ошибки необходимо использовать выборку не менее чем из 100–120 образцов. На практике это означает, что предложенный метод требует достаточно объемной предварительной подготовки для набора необходимого числа записей данных от каждого конкретного испытуемого.

IV. Выводы

В данной работе предложен нейросетевой алгоритм косвенной оценки АД по сигналам ЭКГ и ФПГ в условиях высоких шумов. Показано, что для отдельного пациента удастся получить достаточно высокую точность предсказания величин артериального давления. Дальнейшие усилия предполагается направить на построение универсальной модели, которая путем относительно компактной процедуры дообучения может быть адаптирована к данным любого пациента. Также планируется поиск резервов для снижения требований к необходимому объему обучающей выборки, что откроет дорогу к практическому внедрению предложенного метода в портативных приборах, предназначенных для текущего контроля состояния сердечно-сосудистой системы как здоровых людей, так и пациентов, страдающих заболеваниями сердечно-сосудистой системы.

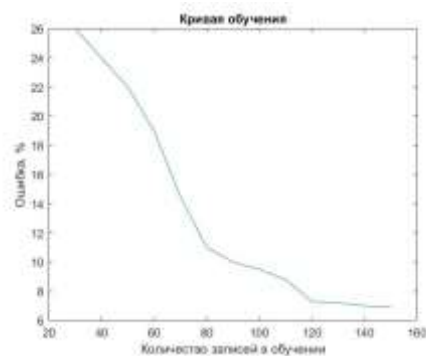


Рис. 4. Зависимость ошибки предсказания от объема обучающей выборки

СПИСОК ЛИТЕРАТУРЫ

- [1] Jermana L. Moraes, Matheus X. Rocha, Glauber G. Vasconcelos, José E. Vasconcelos Filho, Victor Hugo C. de Albuquerque and Auzuir R. Alexandria. *Advances in Photoplethysmography Signal Analysis for Biomedical Applications*. Sensors vol. 18, 9 июня 2018. 2-9 с.
- [2] Kengo Atomi, Haruki Kawanaka, Md. Shoaib Bhuiyan, and Koji Oguri. *Cuffless Blood Pressure Estimation Based on Data-Oriented Continuous Health Monitoring System*. Hindawi Computational and Mathematical Methods in Medicine. 24 апреля 2017. 3-4 с.
- [3] Sagirova Z., Kuznetsova N., Gogiberidze N., Gognieva D., Suvorov A., Chomakhidze P., Omboni S., Saner H., Kopylov P. *Cuffless Blood Pressure Measurement Using a Smartphone-Case Based ECG Monitor with Photoplethysmography in Hypertensive Patients*. Sensors. 2021 May 19; 21(10):3525.
- [4] Syed Ghufuran Khalid, Jufen Zhang, Fei Chen, and Dingchang Zheng. *Blood Pressure Estimation Using Photoplethysmography Only: Comparison between Different Machine Learning Approaches*. Hindawi Journal of Healthcare and Engineering. 23 октября 2018. 2-5 с.
- [5] Moajjem Hossain Chowdhury, Md Nazmul Islam Shuzan, Muhammad E.H. Chowdhury, Zaid B. Mahbub, M. Monir Uddin, Amith Khandakar and Mamun Bin Ibne Reaz. *Estimating Blood Pressure from the Photoplethysmogram Signal and Demographic Features Using Machine Learning Techniques*. Sensors, 1 июня 2020. 4-15 с.
- [6] Pan, J. and Tompkins, W. (1985) *A Real Time QRS Detection Algorithm*. IEEE Transactions on Biomedical Engineering, 32, 230-236.