

Оценка артериального давления по сигналу фотоплетизмограммы на основе комбинированной конфигурации искусственной нейронной сети

А. Н. Калиниченко¹, Н. О. Антипов², А. А. Анисимов³
Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)

¹ank-bs@yandex.ru, ²jobber1994@mail.ru, ³aanisimov@etu.ru

Аннотация. В работе представлена методика создания индивидуализированной модели предсказания артериального давления человека по сигналу фотоплетизмограммы (ФПГ). Используемые сигналы имели высокий уровень шумов, так как их регистрация выполнялась с помощью носимого устройства в неблагоприятных условиях. Поэтому большое внимание было уделено очистке сигнала от помех. Для получения оценок артериального давления использовалась комбинация двух алгоритмов машинного обучения с различным подходом к анализу данных, в частности одномерной сверточной нейронной сети и полносвязной сети прямого распространения. На вход сверточной сети подавались фрагменты сигнала фотоплетизмограммы, а на вход сети прямого распространения – набор рассчитанных по циклам ФПГ признаков. Показано, что комбинация двух альтернативных конфигураций нейронных сетей позволяет получать более точные оценки артериального давления, чем каждая из сетей по отдельности.

Ключевые слова: фотоплетизмограмма; безманжетная оценка артериального давления; искусственные нейронные сети

I. ВВЕДЕНИЕ

Для оценки артериального давления (АД) людей в настоящее время наиболее распространенным является манжетный метод, в силу его простоты и доступности. Однако данный метод имеет ряд ограничений и неудобств при использовании. Для устранения этих недостатков предпринимаются многочисленные исследования, направленные на создание эффективных методов 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 портативного кардиомонитора CardioQvark [3]. Поскольку регистрация сигналов с помощью подобных устройств может происходить в неблагоприятных условиях, получаемые сигналы могут иметь высокий уровень шумов, что существенно затрудняет или делает невозможным использование этих данных для анализа. Одной из целей работы было создание алгоритма подавления шумов в

сигнале для обеспечения возможности его последующего использования в алгоритмах машинного обучения (МО), которые часто применяются в безманжетных методах косвенной оценки АД [4, 5].

Для получения оценок артериального давления использовалась комбинация двух алгоритмов машинного обучения с различным подходом к анализу данных, в частности одномерной сверточной искусственной нейронной сети (ИНС) и полносвязной сети прямого распространения. На вход сверточной сети подавались фрагменты сигнала фотоплетизмограммы, а на вход сети прямого распространения – набор рассчитанных по циклам ФПГ признаков. Показано, что комбинация двух альтернативных конфигураций нейронных сетей позволяет получать более точные оценки артериального давления, чем каждая из сетей по отдельности.

II. МАТЕРИАЛЫ И МЕТОДЫ

В настоящей работе исследовалась возможность создание эффективного алгоритма оценки артериального давления по данным только одного пациента, что позволило создать индивидуализированную модель предсказания, учитывающую характерные для данного пациента свойства сигналов. Выборка состояла из 510 записей сигналов ЭКГ и ФПГ продолжительностью по 180 с. Исходная частота отсчетов сигналов составляла 1000 Гц. Данный набор был сформирован в результате визуального отбора записей с целью исключения из исследования реализаций с чрезмерно высоким содержанием помех. Для каждой из записей имелась контрольная оценка величин артериального давления, которые измерялись при помощи бытового тонометра сразу же после окончания сеанса записи сигналов.

A. Предварительная обработка сигналов

В работе использовались два синхронно зарегистрированных сигнала – ЭКГ и фотоплетизмограмма. Исходные сигналы, как правило, имели высокий уровень шумов, на сигнале ФПГ наблюдалось 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).

Для устранения высокочастотных помех использовался фильтр низких частот (ФНЧ) с частотой среза 35 Гц, после чего частота отсчетов сигналов

понижалась до 250 Гц. С целью устранения сетевой наводки использовался адаптивный режекторный фильтр с частотой подавления 50 Гц.

Для выделения кардиоциклов ЭКГ использовался алгоритм Пана–Томпкинса [6]. Найденные при этом опорные точки кардиоциклов использовались далее для определения начальных точек циклов ФПГ. Для устранения плавания нулевой линии в сигнале ФПГ использовалась кубическая сплайн-интерполяция. В качестве узлов интерполяции использовались локальные минимумы каждой из волн. В результате вычитания сплайна получался сигнал, избавленный от плавания нулевой линии (рис. 1).

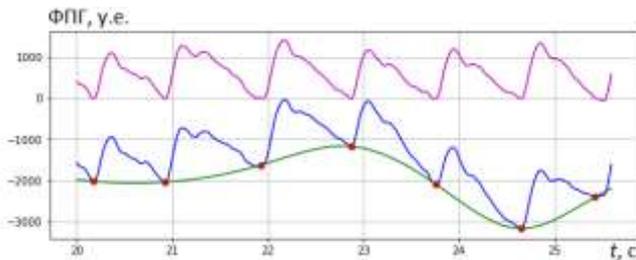


Рис. 1. Результат сплайн-интерполяции. Нижние кривые – фрагмент сигнала ФПГ с выраженным плаванием нулевой линии; жирными точками на сигнале отмечены найденные узлы интерполяции, через которые прошел рассчитанный сплайн. На верхнем графике показан сигнал ФПГ после вычитания сплайна

В. Формирование набора типовых волн ФПГ

Для выбора из сигналов волн ФПГ, пригодных для дальнейшего использования в процессе обучения ИНС, рассчитывался коэффициент взаимной корреляции волн между собой и строилась корреляционная матрица. Волны, имеющие высокую степень коррелированности, отбиралась для дальнейшего использования, пороговое значение коэффициента корреляции составляло 0,95. Волны, не прошедшие данный порог из-за высокого уровня помех, исключались из дальнейшего анализа. Из отобранных в результате циклов ФПГ на каждом локальном участке длительностью 15 с методом синхронного усреднения рассчитывались усредненные модели, которые далее служили образцами циклов ФПГ для алгоритмов машинного обучения. Участки по 15 с брались с перекрытием 7,5 с. В итоге из каждой записи сигнала могло быть получено до 23 образцов циклов ФПГ. На рис. 2 показаны примеры ансамблей циклов, полученных для трех разных записей с существенно отличающимися значениями артериального давления.

С. Расчет признаков волн ФПГ

В качестве входных данных для полносвязной ИНС рассчитывался набор из 20 различных признаков, определяемых по волнам ФПГ. Каждый из признаков исследовался на информативность, устойчивость и коррелированность с другими признаками. Также была проведена проверка на комбинаторную эффективность различных групп признаков с использованием программного пакета Regression Learner в среде MATLAB.

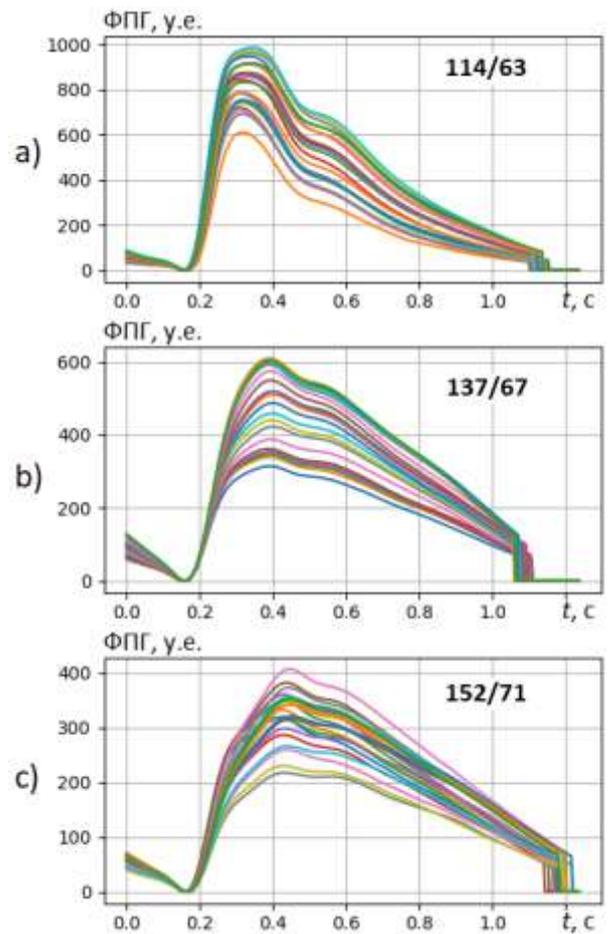


Рис. 2. Ансамбли усредненных циклов ФПГ для трех записей сигналов, которым соответствуют различные значения измеренного давления: а) 114/63 мм рт. ст.; б) 137/67 мм рт. ст.; в) 152/71 мм рт. ст.

В итоге были отобраны следующие 9 признаков, которые, с одной стороны, демонстрировали значимую информативность, а с другой – не были коррелированы друг с другом:

- СКО отсчетов сигнала;
- продолжительность импульса;
- отношение максимальных пиков 1 и 2 производной;
- отношение минимальных пиков 1 и 2 производной;
- амплитуда пиков 1 производной;
- амплитуда пиков второй производной;
- R-R интервал, предшествующий волне;
- амплитуда систолического пика;
- амплитуда максимального пика 1 производной.

На рис. 3 показан образец усредненного цикла ФПГ и его первых двух производных.

Д. Формирование уравновешенной обучающей выборки

Как правило, величины давления каждого конкретного человека тяготеют к некоторому наиболее типичному для него среднему значению. При этом распределение значений давления обычно близко напоминает нормальный закон (рис. 4а). В связи с этим, случайный выбор образцов из всего доступного набора приведет к получению неуравновешенной по

контрольным значениям выборки. В конечном итоге обученная на таком наборе сеть будет точно предсказывать только значения из центральной части диапазона давлений, так как эти значения будут доминировать в обучающей выборке.

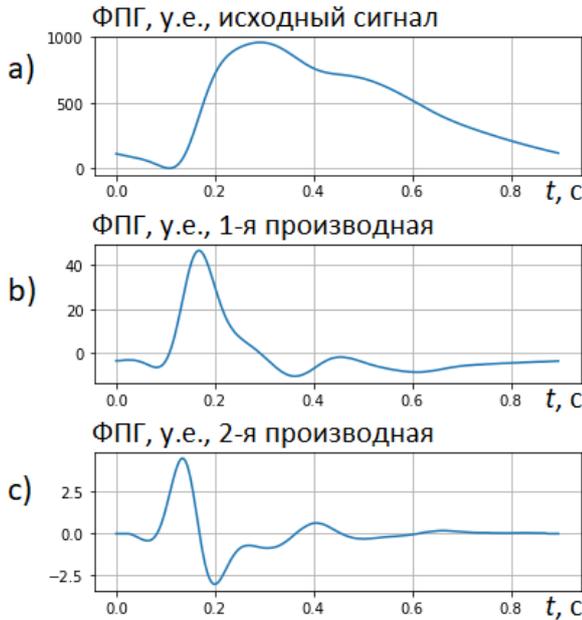


Рис. 3. Образец усредненного цикла ФПГ (а), его первой (б) и второй (с) производных

Чтобы избежать данного нежелательного эффекта, был разработан специальный алгоритм отбора записей, результат работы которого иллюстрируется на рис. 4. В данном примере была поставлена задача сформировать обучающий набор, включающий 100 записей ФПГ и контрольный набор, содержащий 50 записей. При этом распределение давлений для каждого из наборов должно было быть по возможности близким к равномерному. На рис. 4а приведено распределение значений систолического артериального давления для всего набора, включающего 510 записей. На рис. 4б показано распределение для обучающей выборки из 100 записей. Распределение для оставшихся после этого записей приведено на рис. 4с, а на рис. 4д показано полученное распределение для контрольной выборки из 50 записей ФПГ. Как можно видеть, и обучающая и контрольная выборки уравновешены по давлению существенно лучше, чем полный набор данных.

Е. Нейросетевая модель предсказания артериального давления

В настоящем исследовании использовались три альтернативных модели ИНС – полносвязная нейронная сеть прямого распространения, одномерная сверточная нейронная сеть, а также их комбинация (ансамбль).

Для создания моделей предсказания использовался фреймворк Keras на языке программирования Python. Было создано две модели предсказания – полносвязная сеть прямого распространения, в которой используется набор коррелирующих с давлением информативных признаков 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 в большей мере оценивает наиболее общие характеристики сигнала.

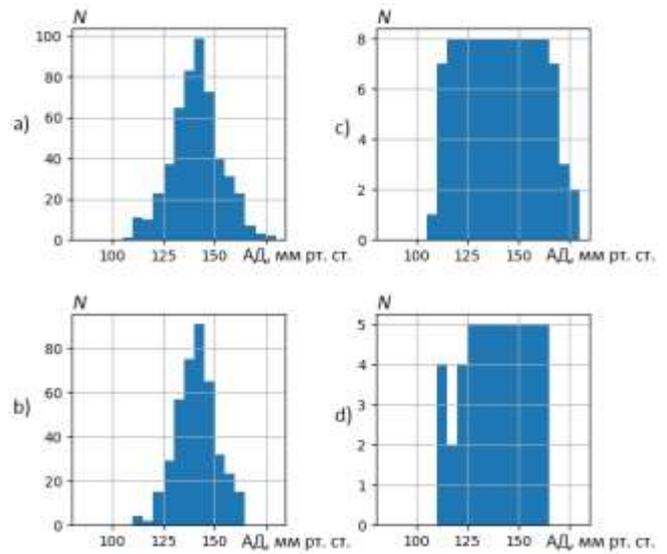


Рис. 4. Гистограммы распределений давления для полного набора данных (а), обучающей (б) и контрольной выборок (д), а также для полного набора после изъятия обучающей выборки (с)

В качестве входных данных для сверточной ИНС использовались отобранные очищенные от помех волны с высокой степенью корреляции (см. выше). Для анализа сигналов формировались окна свертки послойно уменьшающиеся в размере по мере прохождения слоев, тем самым отбирая наиболее информативные признаки.

Для обеих моделей исследовалось влияние их гиперпараметров на точность предсказания давления. Полученные наиболее удачные конфигурации тестировались по отдельности, а далее были взяты за основу ансамбля моделей, включающего две параллельные ветви, результаты работы которых объединяются на завершающих стадиях анализа данных (рис. 5).

В табл. 1 приведены основные параметры ансамбля моделей, а также сведения о применявшихся процедурах регуляризации.

III. РЕЗУЛЬТАТЫ

Для оценки точности модели в качестве метрики использовалась средняя абсолютная ошибка, для оценки функции потерь использовалась среднеквадратичная ошибка. Стоит отметить особенности полученных результатов для каждой из моделей. Предсказания, полученные от полносвязной ИНС имеют меньшую 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. 2 представлены результаты, полученные для каждой из моделей.

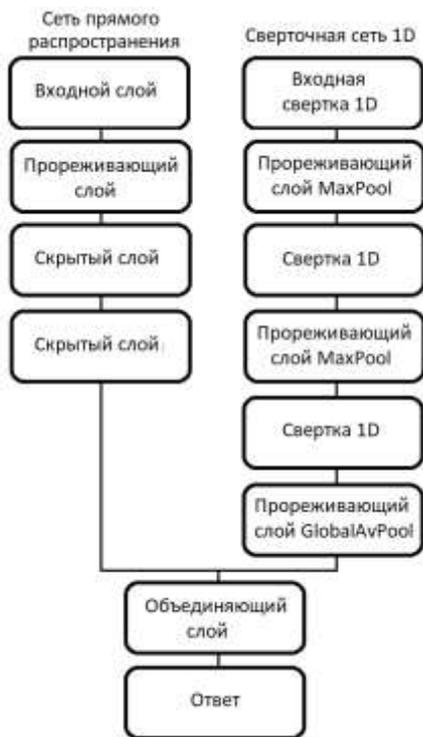


Рис. 5. Архитектура ансамбля моделей ИНС

ТАБЛИЦА I ПАРАМЕТРЫ МОДЕЛЕЙ

Параметр	Полносвязная ИНС	Сверточная ИНС
Размер модели	2 – скрытых слоя, 1 – прореживающий, 1 – регрессионный слой	3 – сверточных слоя, 3 прореживающих окна свертки 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

ТАБЛИЦА II РЕЗУЛЬТАТЫ ПРЕДСКАЗАНИЯ ДЛЯ КАЖДОЙ ИЗ МОДЕЛЕЙ

Наименование выборки	Средняя абсолютная ошибка, мм. рт. ст.	Средняя относительная ошибка, %
<i>Модель сверточной нейронной сети</i>		
Обучающая	9,1	6,5
Валидационная	9,65	6,89
Тестовая	10,35	7,39
<i>Модель полносвязной нейронной сети</i>		
Обучающая	5,37	3,83
Валидационная	6,6	4,71
Тестовая	8,0	5,71
<i>Ансамбль моделей</i>		
Тестовая	7,3	5,21

IV. ВЫВОДЫ

В данной работе предложен алгоритм косвенной оценки АД по сигналу ФПГ для одного пациента в условиях высоких шумов. Основная задача работы заключалась в создании подхода, который был бы универсален для любого пациента, что позволило бы учесть индивидуальные особенности каждого пациента.

Главным недостатком предложенного подхода является необходимость предварительного сбора достаточно большого числа записей (не менее 50) для обучения.

Полученные результаты демонстрируют точность предсказания величин давления, сопоставимую с аналогичными характеристиками манжетных тонометров. Это означает, что метод, в случае его внедрения в практическую аппаратуру, может служить альтернативой традиционным способам контроля артериального давления людей.

СПИСОК ЛИТЕРАТУРЫ

- [1] Jermama 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 (Basel). 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] Рангайян Р.М. Анализ биомедицинских сигналов. Практический подход. М.: ФИЗМАТЛИТ, 2007. 440 с.