Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение
высшего образования
«Уральский федеральный университет
имени первого Президента России Б.Н. Ельцина»
Институт радиоэлектроники и информационных технологий - РТФ
Кафедра информационных технологий и систем управления

ДОПУСТИТЬ К ЗАЩИТЕ ПЕРЕД ГЭК

Зав. кафедрой ИТиСУ
_____ Е.В. Кислицын
(подпись) (Ф.И.О.)
«04» 06 2024 г.

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА

ИССЛЕДОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРЕДСКАЗАНИЯ СИСТОЛИЧЕСКОГО И ДИАСТОЛИЧЕСКОГО АРТЕРИАЛЬНОГО ДАВЛЕНИЯ ПО ПРИЗНАКАМ СИГНАЛА ФОТОПЛЕТИЗМОГРАММЫ

Научный руководитель: Долганов Антон Юрьевич
к.т.н., доцент _____
подпись

Нормоконтролер: Бредихина Наталья Сергеевна _____
подпись

Студент группы: РИМ-220908 Мишанина Дарья Владимировна _____
подпись

Екатеринбург
2024

Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение высшего образования
**«Уральский федеральный университет
имени первого Президента России Б.Н. Ельцина»**

Институт радиоэлектроники и информационных технологий - РТФ
Кафедра информационных технологий и систем управления
Направление подготовки 09.04.01 Информатика и вычислительная техника
Образовательная программа Инженерия искусственного интеллекта

ЗАДАНИЕ

на выполнение выпускной квалификационной работы

студента Мишаниной Дарьи Владимировны группы РИМ-220908
(фамилия, имя, отчество)

1. Тема выпускной квалификационной работы Исследование методов машинного обучения для предсказания систолического и диастолического артериального давления по признакам сигнала фотоплетизмограммы

Утверждена распоряжением по институту от «4» декабря 2023 г. № 33.02-05/298

2. Научный руководитель Доганов Антон Юрьевич, доцент, кандидат технических наук
(Ф.И.О., должность, ученая степень, ученое звание)

3. Исходные данные к работе научно-исследовательские работы, открытые наборы данных биологических сигналов

4. Перечень демонстрационных материалов *презентация в MS PowerPoint*

5. Календарный план

№ п/п	Наименование этапов выполнения работы	Срок выполнения этапов работы	Отметка о выполнении
1.	Обзор источников литературы	до 24.03.2024 г.	
2.	Используемые данные, методы и метрики исследования	до 28.04.2024 г.	
3.	Полученные результаты и их интерпретация	до 19.05.2024 г.	
4.	ВКР в целом	до 20.05.2024 г.	

Научный руководитель Долганов Антон Юрьевич _____ (подпись)
Ф.И.О.

Студент задание принял к исполнению 12.02.2024 _____ (подпись)
дата

6. Допустить Мишанину Дарью Владимировну к защите выпускной квалификационной работы в экзаменационной комиссии

Зав. кафедрой ИТиСУ _____ Е.В. Кислицын
(подпись) Ф.И.О.

РЕФЕРАТ

Выпускная квалификационная работа магистра содержит 87 страниц без учета приложений, 22 рисунка без учета рисунков в приложениях, 4 таблицы без учета таблиц в приложениях, 45 источников, 6 приложений. Работа состоит из введения, 3 основных глав и заключения.

АРТЕРИАЛЬНОЕ ДАВЛЕНИЕ, СИСТОЛИЧЕСКОЕ ДАВЛЕНИЕ, ДИАСТОЛИЧЕСКОЕ ДАВЛЕНИЕ, ФОТОПЛЕТИЗМОГРАММА, ФПГ, МАШИННОЕ ОБУЧЕНИЕ.

Объект исследования: алгоритмы косвенной оценки артериального давления на основе параметров биологических сигналов.

Предмет исследования: методы извлечения признаков биологических сигналов и модели машинного обучения.

Цель работы: разработка прототипа алгоритма машинного обучения, позволяющего предсказывать систолическое и диастолическое артериальное давления с использованием признаков сигнала фотоплетизмограммы.

Методы исследования: изучение и анализ научно-исследовательских работ, обработка сигналов и извлечение признаков, модели машинного обучения и оценка их производительности, сравнительный анализ, интерпретация результатов.

Результаты работы: разработан прототип алгоритма машинного обучения, позволяющий предсказать систолическое и диастолическое артериальное давление с использованием признаков сигнала фотоплетизмограммы. Основные результаты в формате тезисов приняты к публикации в сборнике всероссийской научной студенческой конференции «ИНТЕР – Информационные технологии и радиоэлектроника», а также представлены на постерной секции в рамках международной конференции 2024 USBEREIT.

ПЕРЕЧЕНЬ СОКРАЩЕНИЙ И ОБОЗНАЧЕНИЙ

В настоящей работе применяются следующие сокращения и обозначения:

АД – Артериальное давление

ВОЗ – Всемирная Организация Здравоохранения

ВСР – Вариабельность сердечного ритма

ФПГ - Фотоплетизмограмма

ЭКГ – Электрокардиограмма

AAMI – Association for the Advancement of Medical Instrumentation (перевод с англ. — Ассоциация развития медицинского оборудования)

AdaBoost – нейронная сеть Adaptive Boosting (перевод с англ. — адаптивный бустинг)

BP – Blood Pressure (перевод с англ. — артериальное давление)

CatBoost – название модели градиентого бустинга на основе деревьев решений

DBP – Diastolic blood pressure (перевод с англ. — диастолическое артериальное давление)

DT – Diastolic time (перевод с англ. — диастолическое время)

HRV – Heart rate variability (перевод с англ. — вариабельность сердечного ритма)

LightGBM – нейронная сеть Light Gradient Boosting Machine (перевод с англ. — облегченный метод на основе градиентного бустинга)

LSTM – нейронная сеть Long Short-Term Memory (перевод с англ. — длительная краткосрочная память)

LR – Linear Regression (перевод с англ. — линейная регрессия)

LRCN – нейронная сеть Long-term Recurrent Convolutional Network (перевод с англ. — долгосрочная рекуррентная сверточная нейронная сеть)

MAE – Mean absolute error (перевод с англ. — средняя абсолютная ошибка)

ME – Mean error (перевод с англ. — средняя ошибка)

MIMIC – Medical Information Mart for Intensive Care (перевод с англ. — Медицинская информационная карта для интенсивной терапии)

MLP – нейронная сеть Multi Layer Perceptron (перевод с англ. — многослойный перцептрон)

MLPBP – нейронная сеть Multi Layer Perceptron Blood Pressure (перевод с англ. — многослойный перцептрон для оценки артериального давления)

PAT – Pulse arrival time (перевод с англ. — время прибытия пульсовой волны)

PPG – Photoplethysmogram (перевод с англ. — фотоплетизмограмма)

PPGIABP – нейронная сеть Photoplethysmogram Info Ambulatory blood pressure (перевод с англ. — информация по фотоплетизмограмме для амбулаторного артериального давления)

PTT – Pulse transit time (перевод с англ. — время распространения пульсовой волны)

PWA – Pulse wave analysis (перевод с англ. — анализа пульсовой волны)

PWV – Pulse wave velocity (перевод с англ. — скорость распространения пульсовой волны)

RMSE – Root Mean Square Error (перевод с англ. — средняя квадратическая ошибка)

R2 – Коэффициент детерминации

ResNet – нейронная сеть Residual Neural Network (перевод с англ. — нейронная сеть с остаточными соединениями)

RR – Временной интервал между соседними систолическими пиками фотоплетизмограмы, соответвующий временному интервалу между зубцами R электрокардиограммы соседних сердечных сокращений

SBP – Systolic blood pressure (перевод с англ. — систолическое артериальное давление)

SE-MSResUNet – нейронная сеть Squeeze-Excitation Multi-Scale Residual U-Net (перевод с англ. — много масштабная нейронная сеть на основе

архитектуры в форме буквы “U” с остаточными связями и модулем сжатия-возбуждения)

SGDRegressor – Stochastic Gradient Descent Regressor (перевод с англ. — регрессор с применением стохастического градиентного спуска)

SHAP – SHapley Additive exPlanations (перевод с англ. - аддитивные объяснения Шэпли)

SpectroResNet – нейронная сеть Spectro Residual Neural Network (перевод с англ. — нейронная сеть с остаточными соединениями для извлечения спектральной информации)

ST – Systolic time (перевод с англ. — систолическое время)

STD – Standard deviation (перевод с англ. — среднеквадратичное отклонение)

SVM – Support Vector Machine (перевод с англ. — метод опорных векторов)

SVR – Support Vector Regression (перевод с англ. — регрессия на основе метода опорных векторов)

U-Net – нейронная сеть “U” Neural Network (перевод с англ. — нейронная сеть с архитектурой в форме буквы “U”)

UCI – University of California Irvine Machine Learning Repository (перевод с англ. — Репозиторий машинного обучения Калифорнийского университета в Ирвине)

V-Net – нейронная сеть “V” Neural Network (перевод с англ. — нейронная сеть с архитектурой в форме буквы “V”)

RF – Random Forest (перевод с англ. — случайный лес)

СОДЕРЖАНИЕ

ВВЕДЕНИЕ 9
1 Обзор источников литературы 12
1.1 Обзор методов оценки артериального давления 12
1.2 Анализ текущих исследований по задаче определения артериального давления методами машинного обучения по сигналу фотоплетизмограммы 16
1.3 Обзор открытых баз данных сигналов артериального давления и фотоплетизмограммы. Выбор данных для исследования 25
1.4 Выводы и направление дальнейшего исследования 29
2 Используемые данные, методы и метрики исследования 33
2.1 Описание используемого набора данных 33
2.2 Последовательность этапов исследования 34
2.3 Извлечение целевых показателей систолического и диастолического АД 36
2.4 Извлечение морфологических признаков сигнала ФПГ 38
2.5 Извлечение признаков вариабельности сердечного ритма сигнала ФПГ 40
2.6 Извлечение частотных признаков сигнала ФПГ 42
2.7 Используемые модели машинного обучения 45
2.8 Методы для оценки значимости признаков и интерпретации результатов 46
2.9 Метрики для оценки производительности моделей машинного обучения 49
3 Полученные результаты и их интерпретация 51
3.1 Сравнение производительности моделей машинного обучения в соответствии с группами признаков сигнала ФПГ 51
3.2 Значимость признаков и интерпретация полученных результатов модели для оценки систолического АД 53

3.3 Значимость признаков и интерпретация полученных результатов модели для оценки диастолического АД 61
3.4 Обсуждение полученных результатов..... 71
3.5 Сравнение полученных результатов с результатами аналогичных исследований. 75
ЗАКЛЮЧЕНИЕ 79
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ 81
ПРИЛОЖЕНИЕ А 88
ПРИЛОЖЕНИЕ Б..... 92
ПРИЛОЖЕНИЕ В 96
ПРИЛОЖЕНИЕ Г..... 99
ПРИЛОЖЕНИЕ Д 102
ПРИЛОЖЕНИЕ Е..... 103

ВВЕДЕНИЕ

По данным Всемирной организации здравоохранения (ВОЗ), гипертония является одной из ведущих причин смертности во всем мире [38]. Гипертонией называется состояние, при котором артериальное давление превышает нормальные показатели 140 мм рт. ст. для систолического АД или 90 мм рт. ст. для диастолического АД. Гипертония широко распространена среди населения, но при отсутствии лечения может приводить к серьезным последствиям, таким как инсульт, инфаркт, заболевания почек и др.

Согласно статистическим данным ВОЗ, гипертония имеется у 1.28 млрд взрослых людей в возрасте от 30 до 79 лет во всем мире, две трети из которых проживают в странах с низким или средним уровнем дохода. Согласно приведенным оценкам, 46% взрослых с гипертонией не подозревают о наличии у себя заболевания. Диагностикой и лечением охвачено всего 42% взрослых пациентов с гипертонией. Только 21% взрослых пациентов с гипертонией контролируют данное заболевание. Сокращение распространенности гипертонии входит в число глобальных целей ВОЗ в области борьбы с неинфекционными заболеваниями [38].

Единственным способом выявления гипертонии является измерение артериального давления медицинским специалистом. Одним из способов уменьшения риска, согласно рекомендациям ВОЗ, является регулярная проверка артериального давления [38]. В настоящее время наиболее популярным и общедоступным способом определения артериального давления является осциллометрический метод, при котором используется измерительное устройство с автоматически надуваемой манжетой со встроенным датчиком давления. Недостатками данного метода являются остановка кровотока, невозможность непрерывного измерения, а также дискомфорт для пациента.

Подобные проблемы решают косвенные алгоритмы измерения артериального давления на основе параметров биологических сигналов,

характеризующих движение крови по артериям, основными из которых является электрокардиограмма и фотоплетизмограмма. К данным алгоритмам относятся методы на основе времени распространении пульсовой волны, времени прибытия пульсовой волны и скорости распространения пульсовой волны. В свою очередь, главным недостатком данных методов является необходимость в постоянной калибровке.

В последнее время для непрерывного определения артериального давления активно исследуются возможности применения методов машинного обучения, в частности, с помощью анализа пульсовой волны. Преимущество данного подхода заключается в простом и комфортном для пациента непрерывном измерении артериального давления, с использованием только одного датчика для регистрации фотоплетизмограммы.

Целью настоящего исследования является разработка прототипа алгоритма машинного обучения, позволяющего предсказывать систолическое и диастолическое артериальное давления с использованием признаков сигнала фотоплетизмограммы.

Для достижения поставленной цели настоящего исследования необходимо решить следующие задачи:

1) выполнить обзор источников литературы,

2) выбрать набор данных, методы и метрики для оценки результатов,

3) выполнить сравнение методов машинного обучения и интерпретировать полученный результат.

Объектом исследования являются алгоритмы косвенной оценки артериального давления на основе параметров биологических сигналов.

Предметом исследования являются методы извлечения признаков биологических сигналов и модели машинного обучения.

Методы исследования включают в себя:

– методы изучения и анализа научно-исследовательских работ предметной области,

– методы обработки сигналов и извлечения признаков,

– методы машинного обучения,

– методы оценки производительности моделей машинного обучения,

– методы сравнительного анализа результатов различных моделей машинного обучения,

– методы анализа и интерпретации результатов моделей машинного обучения.

Практическая значимость данной работы заключается в использовании полученных результатов для разработки наиболее эффективной интерпретируемой модели машинного обучения для определения систолического и диастолического артериального давления с помощью фотоплетизмограммы и дальнейшего применения в медицинских измерительных приборах.

1 Обзор источников литературы

1.1 Обзор методов оценки артериального давления

Артериальным давлением называется давление, которое кровь оказывает на стенки артерии. Колебания артериального давления обусловлены периодическим характером сокращения сердца. В период сокращения сердца на стенки артерии оказывается максимальное артериальное давление, которое называется систолическим. В момент максимального расслабления сердца на стенки артерии оказывается минимальное артериальное давление, которое называется диастолическим.

Приведено подробное описание методов измерения артериального давления в хронологическом порядке возникновения в работе [32]. Методы оценки артериального давления приведены на рисунке 1.

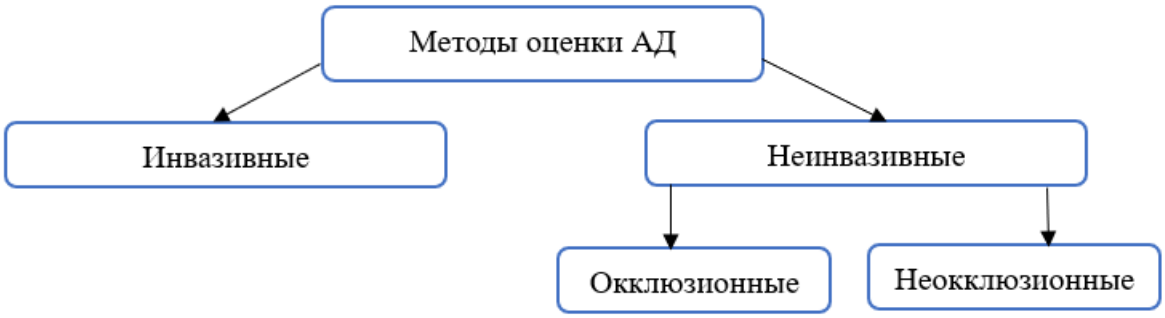

Рисунок 1 – Классификация методов оценки артериального давления

Методы оценки артериального давления делятся на две основные группы: инвазивные и неинвазивные. Инвазивное измерение проводится в стерильной среде с помощью хирургического вмешательства. При этом в артерию вводится катетер, с помощью которого давление крови в артериях преобразуется в электронные сигналы. При неинвазивных методах хирургическое вмешательство отсутствует. В свою очередь, неинвазивные методы оценки артериального давления делятся на окклюзионные и неокклюзионные.

Окклюзионные методы подразумевают полную или частичную остановку кровотока. По данной причине окклюзионные методы измерения вызывают дискомфорт у пациента, а также не могут быть применены для непрерывного измерения артериального давления. Наиболее широко применимым окклюзионным методом является осциллометрическое измерение артериального давления. При этом используется измерительное устройство с автоматически надуваемой манжетой со встроенным датчиком, который преобразует данные артериального давления в электрические сигналы. Предшественником осциллометрического измерения является аускультативный метод, который также называют методом Короткова. Данный метод основан на определении звуков пульсации артерии, выслушиваемых при прохождении тона крови под манжетой, обернутой вокруг плеча пациента. Также существует тонометрическое измерение, при котором кровоток останавливается не полностью, при этом датчик давления располагается непосредственно на артерии.

Неокклюзионные методы подразумевают оценку артериального давления на основе характеристик биологических сигналов, которые зависят от движения крови по артериям, таких как электрокардиограмма, фотоплетизмограмма и др. Приведено описание неокклюзионных методов оценки давления в работе [22]. Одним из таких методов является метод на основе времени распространении пульсовой волны (PTT), которое рассчитывается как время распространения пульсовой волны из одной точки тела в другую, что соответствует временному интервалу между систолическими пиками на фотоплетизмограмах. Для измерения PTT используются два датчика для регистрации фотоплетизмограммы в выбранных проксимальной и дистальной точках тела. Отмечается зависимость между значениями артериального давления и PTT [35]. Данный метод требует персональной калибровки. Другим методом является метод на основе времени прибытия пульсовой волны (PAT), которое определяется как временной интервал между электрической активацией сердца, советующей зубцу R на

электрокардиограмме, и систолической точкой фотоплетизмограммы. Для измерения данного времени используются два датчика: для регистрации электрокардиограммы и фотоплетизмограммы в выбранной точке тела. Данный метод также требует персональной калибровки. Учитывая некоторые разногласия в терминологии, следует отметить, что часть исследователей под методом PTT подразумевает метод PAT. На рисунке 2 наглядно представлено различие между PAT и PTT [3].

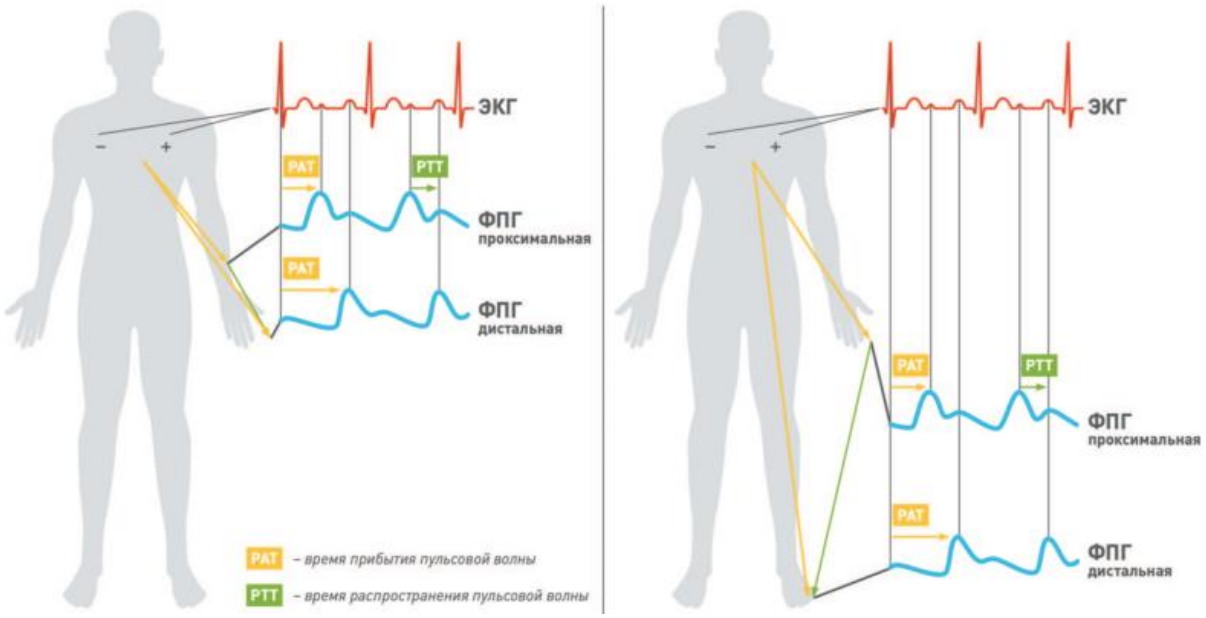

Рисунок 2 – Различие между временем прибытия пульсовой волны (PAT) и временем распространения пульсовой волны (PTT) [3]

Также применяется метод на основе скорости распространения пульсовой волны (PWV). Уравнение Моенса-Кортевега определяет зависимость между скоростью пульсовой волны и артериальным давлением. Данное уравнение также учитывает индивидуальные физиологические параметры, такие как эластичность сосуда, толщину артериальной стенки, диаметр сосуда и плотность крови. При этом скорость пульсовой волны определяется как отношение расстояния между двумя датчиками фотоплетизпограммы, расположенных на одной ветви артерии, ко времени распространения пульсовой волны (PTT). Индивидуальность

физиологических параметров и необходимость калибровки также ограничивает возможности применения данного метода.

Как упоминается выше, методы на основе определения PTT и PAT используют установленную зависимость со значениями артериального давления. Для определения требуемых коэффициентов проводится необходимая калибровка. По методу на основе PWV артериальное давление определяется на основании уравнения Моенса-Кортевега, также требуется значение PTT. Но указанные характеристики могут применяться также для оценки артериального давления с помощью методов машинного обучения, наряду с другими признаками, которые могут быть извлечены из биологических сигналов, характеризующих движение крови по артериям.

Отмечается все более активное применение методов машинного обучения для определения артериального давления, с использованием признаков электрокардиограммы и фотоплетизмограммы преимущественно в работах [5], [22], [32]. Признаки разных типов извлекаются исследователями из биологических сигналов: морфологические, амплитудные, временные, частотные, признаки производных исследуемых биологических сигналов, нелинейные комбинации извлеченных признаков. Также используются физиологические признаки пациентов, такие как пол, возраст, вест, рост, поскольку отмечается связь с характером кровотока в артериях. В качестве моделей машинного обучения широко применяется линейная регрессия, модели на основе деревьев решений, метод опорных векторов, нейронные сети различных архитектур.

Отдельно отмечается метод анализа пульсовой волны (PWA), который подразумевает обработку сигнала фотоплетизмограммы и извлечение определенных характеристик из формы данной волны [14], [22]. Преимущество данного подхода заключается в том, что для оценки артериального давления требуется только один датчик для регистрации фотоплетизмограммы. Взаимосвязь между артериальным давлением и формой волны фотоплетизмограммы имеет нелинейный характер. В настоящее время

данная взаимосвязь не до конца понятна и изучена, требуются дополнительные исследования для лучшего понимания данного подхода. В перспективе данный метод может обеспечить простую и точную непрерывную оценку артериального давления неинвазивным неокклюзионным способом.

1.2 Анализ текущих исследований по задаче определения артериального давления методами машинного обучения по сигналу фотоплетизмограммы

Было подробно рассмотрено несколько работ, в которых проводилось исследование по определению значений АД только с помощью характеристик сигнала PPG методами машинного обучения. Набор данных либо был подготовлен специально для исследования с участием добровольцев, либо использовался один из открытых медицинских наборов данных.

В качестве основной метрики использовалась средняя ошибка или средняя абсолютная ошибка со стандартным отклонением для расчетных и полученных значений АД. Данные метрики выбирались с целью установления соответствия или не соответствия требованиям стандарта Ассоциации развития медицинского оборудования AAMI. Требования стандарта AAMI определяют среднюю ошибку не более 5 мм рт. ст. и стандартное отклонение не более 8 мм рт. ст. для оценки систолического и диастолического АД с размером выборки не менее 85 субъектов.

Результаты исследований указаны в Таблице 1.

Таблица 1 – Результаты исследований по определению значений АД с использованием характеристик сигнала PPG методами машинного обучения

№	Год	Набор данных	Признаки PPG	Модель	Метрика	Результат SBP, мм рт. ст.	Результат DBP, мм рт. ст.
[34]	2003	15	ST	линейная	ME ±	0.68 ±	0.09 ±

Продолжение таблицы 1

		здоровых мужчин		регрессия	STD	7.52	4.47
			DT			0.21 ± 7.32	0.02 ± 4.39
[29]	2013	MIMIC, 15000 отдельных фаз сигналов	DT	линейная регрессия	MAE ± STD	9.80 ± 8.09	5.88 ± 5.11
			ST, DT, RR, 25/33/50/ 66/75% ST, DT, DT/ST	полносвязная нейронная сеть		3.80 ± 3.46	2.21 ± 2.09
[16]	2018	MIMIC II, 910 отдельных фаз сигналов	ST, DT, RR, 25/33/50/66/75% ST, DT, DT/ST	полносвязная нейронная сеть	MAE ± RMSE	13.4 ± 11.6	6.9 ± 5.9
			ST, DT, RR, 25/33/50/66/75% ST, DT, DT/ST + 14 признаков 2-й производной	метод опорных векторов		8.5 ± 10.5	4.3 ± 5.8
[17]	2016	MIMIC II, 3000 записей	ST+DT, ST, DT, ST/ (ST+DT), 4 статистических временных признака, 19 признаков 2-й производной, 8 нелинейных комбинаций признаков, 11 признаков BCP	сеть из трех полносвязных нейронных сетей	ME ± STD	0.16 ± 6.85	0.03 ± 4.72
[6]	2016	Vital Signs Dataset, 32	11 морфологических признаков (временные, амплитудные, углы,	метод опорных векторов	MAE ± STD	4.77 ± 7.68	3.67 ± 5.69

Продолжение таблицы 1

		записи	площади под кривой, нелинейные комбинации)				
[11]	2018	Vital Signs Dataset, 32 записи	ST, площадь под кривой, время на уровне 1/4 амплитуды	линейная регрессия	ME ± STD	0.5 ± 15.3	0.05 ± 9.0
				метод опорных векторов		3.9 ± 15.9	1.2 ± 8.5
				дерево решений		-0.1 ± 6.5	-0.6 ± 5.2
[23]	2014	Vital Signs Dataset, 32 записи	ST, DT, время на уровне 33% и 75% амплитуды, ЧС	линейная регрессия (для параметров R и C модели Виндкесс ела)	MAE ± STD	0.78 ± 13.1	0.59 ± 10.2
[37]	2016	MIMIC II, 69 записей	амплитудно-частотные признаки БПФ	полносвязная нейронная сеть	MAE ± STD	0.06 ± 5.57	0.01 ± 3.69
[19]	2016	65 здоровых добровольцев	ST, DT, пол, возраст, вейвлет - коэффициенты	метод опорных векторов	MAE ± STD	4.9 ± 4.9	4.3 ± 3.7
[21]	2018	205 добровольцев	возраст, пол, вес, рост, 233 временных и частотных признака для сигнала и его производных	линейная регрессия	MAE ± STD	6.9 ± 9.0	5.0 ± 6.1

Продолжение таблицы 1

[25]	2019	265 здоровых добровольцев	76 признаков 2-й производной сигнала	линейная регрессия	MAE (% выборки с < MAE)	5 (38%) 10 (78%) 15 (91%)	-
[7]	2017	MIMIC II, 72 записи	ST, DT, 20 признаков спектральной плотности мощности	полносвязная нейронная сеть	ME ± STD	-0.0217 ± 4.8950	0.0975 ± 2.9160
[28]	2013	525 пациентов	-	нейронная глубокая сеть доверия	ME ± STD	-2.98 ± 19.35	-3.65 ± 8.69
[13]	2016	MIMIC, 42 записи	-	нейронные сети LSTM	RMSE ± STD	2.56 ± 1.25	1.98 ± 1.05
[24]	2018	1363 добровольца	временные и амплитудные, признаки 2-й производной, физиологические признаки, признаки автоэнкодера	полносвязная нейронная сеть	STD	11.76	-
[15]	2023	UCI, 2064 записи	-	нейронная сеть SE-MSResUNet	MAE ± STD	3.88 ± 6.17	2.16 ± 3.75

Исследование проводилось на 15 здоровых мужчинах, которые выполняли последовательность упражнений в работе [34]. Сигнал PPG регистрировался в течение 18 секунд с частотой 1кГц. Артериальное давление регистрировалось неинвазивным способом. В качестве признаков

рассматривалось 4 морфологических временных признака формы сигнала PPG: время систолы, время диастолы, время на уровне 1/2 амплитуды, время на уровне 1/3 амплитуды. Было установлено наибольшее значение коэффициента корреляции для признаков времени систолы и времени диастолы со значениями артериального давления. Для оценки значений систолического и диастолического АД применялась модель линейной регрессии, отдельная для признака времени систолы и времени диастолы.

Использована открытая база данных MIMIC, содержащая тысячи обезличенных данных, зарегистрированных у пациентов отделений интенсивной терапии медицинского центра США в работе [29]. База данных MIMIC в том числе содержит множество наборов сигналов PPG и инвазивного АД с частотой дискретизации 125 Гц. В указанной работе было использовано более 15000 отдельно взятых фаз сигналов PPG и инвазивного АД соответственно. Диапазон значений систолического АД составил 70–160 мм. рт. ст., диапазон значений диастолического АД составил 35–90 мм. рт. ст. В качестве признаков был рассмотрен 21 временной морфологический признак формы сигнала PPG: время систолы, время диастолы, время систолы и диастолы на уровнях 25/33/50/66/75% амплитуды, отношение время диастолы ко времени систолы на соответствующих амплитудах, временной интервал между соседними пиками сигнала. Значения систолического и диастолического АД оценивались как максимум и минимум сигнала инвазивного АД соответственно. Для оценки значений АД применялись модели линейной регрессии с признаком времени диастолы, а также полносвязная нейронная сеть с двумя скрытыми слоями и всеми 21 признаками.

Помимо 21 признака из предыдущей работы, было использовано дополнительно 14 признаков, рассчитанных с помощью второй производной сигнала PPG в работе [16]. Форма волны второй производной сигнала PPG содержит пять основных пиков, для которых рассматривались временные промежутки между пиками, а также отношения амплитуд самого сигнала PPG

в точках, соответствующим пикам его второй производной. В качестве набора данных было выбрано 910 отдельных фаз сигналов PPG и инвазивного АД из открытого набора данных MIMIC II с наиболее правильной формой сигнала PPG, для которой вторая производная могла быть построена корректно. Для оценки значений АД применялись модель полносвязной нейронной сети для 21 признака аналогично предыдущей работе, а также метод опорных векторов с нелинейным ядром с использованием всех 35 признаков.

Было использовано 4 морфологических временных признака для формы сигнала PPG, 4 статистических признака для времени фаз сигнала PPG, 19 морфологических признаков для формы сигнала PPG и для формы второй производной сигнала PPG, полученных на основе расположения пиков второй производной, 8 признаков были получены как нелинейных комбинаций указанных признаков, а также 11 признаков, характеризующих вариабельность сердечного ритма, были получены из сигнала PPG, в работе [17]. В качестве набора данных было использовано 3000 записей из открытого набора данных MIMIC II. Были выбраны только данные со значениями систолического АД в диапазоне 80–120 мм. рт. ст. Для оценки значений АД применялись сложная сеть из трех полносвязных нейронных сетей с четырьмя скрытыми слоями. Вычисленная величина диастолического АД использовалась как дополнительный признак на вход сети для расчета систолического АД.

Изначально было рассмотрено 57 морфологических признаков сигнала PPG, которые учитывали различные временные и амплитудные характеристики, участки площади под кривой, величины углов, нелинейные комбинации данных признаков, в работе [6]. В итоге было выбрано по 11 признаков для оценки систолического АД и диастолического АД. При этом использовался открытый набор данных Vital Signs Dataset, включающий записи сигналов PPG с частотой 100 Гц, а также значения неинвазивного АД для 32 пациентов хирургического отделения. Для оценки значений АД применялся метод опорных векторов с радиальным ядром.

Также использовался набор данных Vital Signs Dataset в работе [11]. Было выбрано 3 морфологических признака сигнала PPG: время систолы, площадь под кривой, а также время на уровне 1/4 амплитуды. Для оценки значений АД применялось три модели машинного обучения: линейная регрессия, метод опорных векторов с линейным ядром, дерево решений. Модель дерева решений показала лучший результат из трех моделей.

Использовался набор данных Vital Signs Dataset в похожей работе [23]. Были рассмотрены признаки времени систолы и диастолы, времени на уровне 33% и 75% амплитуды, частота сердечных сокращений. Для оценки значений АД использовалась модель Виндкессела, которая описывает сердечно-сосудистую систему в терминах электрической цепи. Параметры модели сопротивление R и емкость C оценивались с помощью линейной регрессии. Таким образом, через модель Виндкессела были получены значения систолического и диастолического АД.

Была использована открытая база данных MIMIC II в работе [37]. Рассматривалось 69 записей сигналов PPG и инвазивного АД. Диапазон значений систолического АД составил 80–160 мм. рт. ст., диапазон значений диастолического АД составил 40–90 мм. рт. ст. В данном исследовании использовались амплитудно-частотные характеристики сигнала PPG, полученные с помощью быстрого преобразования Фурье. Для оценки значений АД применялась полносвязная нейронная сеть с одним скрытым слоем.

Исследование проводилось на 65 здоровых добровольцах в работе [19]. Сигнал PPG регистрировался с частотой 20 Гц. Были использованы записи длительностью 60 секунд. АД регистрировалось неинвазивным способом. В качестве признаков использовалось время систолы, время диастолы, пол, возраст, а также коэффициенты, полученные с помощью вейвлет-преобразования. Для оценки значений АД применялся метод опорных векторов с радиальным ядром.

Исследование проводилось на 205 добровольцах в работе [21]. Сигналы PPG были получены с помощью датчика сердечного ритма смартфона с частотой 125 Гц в течение 15 минут. Впоследствии использовались отрезки записей длительностью 15 секунд. АД регистрировалось неинвазивным способом. Помимо физиологических признаков (возраст, пол, вес, рост) было извлечено 233 признака из сигнала PPG и его четырех производных во временной и частотных областях. Для оценки значений АД применялась модель линейной регрессии.

Приняли участие 265 здоровых добровольцев в работе [25]. Систолическое АД измерялось неинвазивным способом. Затем проводилось измерение сигнала PPG с помощью пульсоксиметра с частотой дискретизации 20 Гц в течение 20 с. Для извлечения признаков использовали форму волны II производной сигнала PPG. При этом проводились горизонтальные линии с шагом 5% амплитуды. Количество пересечений 2-й производной сигнала PPG и горизонтальных линий, а также временные промежутки между пересечениями применялись в качестве признаков. Физиологические признаки использованы не были, поскольку часть испытуемых предпочла не разглашать личные данные. Итого получилось 76 признаков. Для оценки значений систолического АД применялась линейная регрессия.

Была использована открытая база данных MIMIC II в работе [7]. Рассматривалось 72 записи сигналов PPG и инвазивного АД. В данном исследовании использовались временные морфологические признаки время систолы и время диастолы, а также 20 признаков спектральной плотности мощности, извлеченных из сегментов сигнала PPG в диапазоне частот от 0 до 10 Гц, с линейным разделением по значению частоты с шагом 0.5 Гц. Для оценки значений АД применялась полносвязная нейронная сеть с одним скрытым слоем.

Исследование проводилось на данных 525 пациентах отделения реанимации и интенсивной терапии в работе [28]. Сигналы PPG, а также инвазивного АД записывались в течение 30 минут. В дальнейшем

использовались окна сигналов длительностью 10 с. Для оценки значений АД применялась нейронная глубокая сеть доверия на основе ограниченных машин Больцмана. На вход сети подавался сигнал PPG, на выход подавались максимальные и минимальные значения сигнала инвазивного АД для оценки систолического и диастолического АД соответственно.

Была использована открытая база данных MIMIC в работе [13]. Рассматривалось 42 записи сигналов PPG и инвазивного АД. Для оценки значений АД применялась рекуррентная нейронная сеть с долгой краткосрочной памятью. На вход сети подавались окна сигнала PPG, на выход подавались максимальные и минимальные значения сигнала инвазивного АД для оценки систолического и диастолического АД соответственно. Следует отметить, что для каждой отдельной записи набора данных была обучена отдельная нейронная сеть. Затем результат был усреднен для всех 42 записей.

Приняли участие 1363 добровольца в работе [24]. Систолическое АД измерялось неинвазивным способом каждую минуту, а измерение сигнала PPG проводилось с помощью пульсоксиметра в течение 5 минут. Для извлечения признаков использовалась нейронная сеть автоэнкодера, на вход которой подавался составной сигнал, состоящий из сигнала PPG, а также его I и II производных. Помимо признаков автоэнкодера использовались морфологические временные и амплитудные характеристики сигнала PPG и его II производной, а также физиологические характеристики. Для оценки значений систолического АД применялась полносвязная нейронная сеть с двумя скрытыми слоями. В качестве основной метрики выбран коэффициент корреляции между измеренными и расчетными значениями систолического АД.

Использован набор данных UCI, основанный на очищенных данных открытой базы MIMIC II, в работе [15]. Было выбрано 2064 записи сигналов PPG и инвазивного АД длительностью более 8 минут. Для оценки значений АД применялась специально модернизированная нейронная сеть SE-MSResUNet на основе сети U-net. На вход сети подавались окна сигнала PPG

длительностью 10 с, на выход подавались соответствующие окна сигнала инвазивного АД. При этом данные сигналы предварительно были синхронизированы. Несмотря на достаточно высокую производительность, отмечается низкая способность обобщаемости применения модели к другим наборам данных. При проверке для набора данных MIMIC результат получился значительно ниже, но после калибровки модели получилось улучшить результат.

1.3 Обзор открытых баз данных сигналов артериального давления и фотоплетизмограммы. Выбор данных для исследования

Одной из наиболее популярной и широко используемой базой клинических данных является открытая база данных MIMIC (Medical Information Mart for Intensive Care - Медицинская информационная карта для интенсивной терапии), содержащая обезличенные данные пациентов отделений интенсивной терапии. Набор данных MIMIC стал доступен в основном благодаря работе исследователей из лаборатории вычислительной физиологии Массачусетского технологического института и сотрудничающих исследовательских групп. Требование индивидуального согласия пациента было отменено, поскольку проект не влиял на клиническую помощь, а вся защищенная медицинская информация была деидентифицирована.

Первая версия набора данных MIMIC была опубликована в 2000 году на портале популярного репозитория биомедицинских данных PhysioNet [39]. Данная версия MIMIC включает 121 запись для 90 пациентов отделения интенсивной терапии. Для каждой конкретной записи данные включают волновые сигналы и периодические цифровые показатели жизнедеятельности пациента, полученные с прикроватного монитора, такие как сигналы электрокардиографии, пульскоксиметрии, фотоплетизмограммы, инвазивного артериального давления, легочного артериального давления, венозного артериального давления, а также клинические данные, полученные из

медицинской карты пациента. Средняя продолжительностей записей составляет не менее 20 часов, также есть записи продолжительностью 40 часов и более. Данные, полученные с прикроватных мониторов, делятся на файлы, содержащие по 10 минут записанных сигналов, которые затем могут быть собраны без пробелов в непрерывную запись. База данных MIMIC стала результатом первой попытки создать коллекцию мультипараметрических записей пациентов отделения интенсивной терапии.

Следующая версия базы данных MIMIC II появилась в 2011 году. Начиная с данной версии, база данных подразделяется часть с клиническими данными пациентов MIMIC II Clinical Database и базу данных волновых сигналов и периодических цифровых показателей жизнедеятельности пациентов MIMIC II Waveform Database [40]. В данной версии насчитывается 4897 записей волновых сигналов и 5266 записей периодических цифровых показателей. Но из них только 2809 записей синхронизированы с данными из клинической части базы данных MIMIC II Clinical Database. База данных MIMIC II содержит биологические сигналы и периодические цифровые показатели, которые варьируются в зависимости от выбора, сделанного персоналом отделения интенсивной терапии. Записи для волновых сигналов часто включают один или несколько сигналов электрокардиограммы, сигналы инвазивного артериального давления, сигналы фотоплетизмограммы и дыхания, а также дополнительные формы волны, если они доступны. Периодические цифровые показатели, которые иначе называются трендами, обычно включают частоту сердечных сокращений и дыхания, показатели пульсоксиметрии, систолическое, среднее и диастолическое артериальное давление, а также другие параметры. Длительность записей также варьируется, в основном от несколько дней до нескольких недель. Преимуществом базы данных MIMIC перед MIMIC II является то, что сигналы электрокардиограммы записаны в лучшем качестве с частотой дискретизации 500 Гц вместо 125 Гц для базы данных MIMIC II.

В 2020 году была опубликована база данных MIMIC III Waveform Database, содержащая самую большую на сегодняшний день коллекцию физиологических сигналов, собранных прикроватными мониторами пациентов в отделениях интенсивной терапии для взрослых и новорожденных [41]. Более 44 000 записей были добавлены к существующей базе данных MIMIC II Waveform Database, что в общей сложности составляет 67 830 наборов записей для примерно 30 000 пациентов отделения интенсивной терапии. Примерно для одной трети базы данных (около 22 000 записей от 10 000 пациентов) квалифицированным исследователям со специализированным правами также доступна обширная клиническая информация через клиническую базу данных MIMIC III Clinical Database. В свободном доступе для цели ознакомления находится только поднабор клинической части данных MIMIC III Clinical Database Demo. Большинство записей включают биологические оцифрованные сигналы (электрокардиограмма, дыхание, фотоплетизмограмма, инвазивное артериальное давление) и периодических показатели жизнедеятельности пациентов в течение всего периода пребывания в отделении интенсивной терапии.

Тем не менее, имеются ограничения по использованию и анализу сигналов данной базы данных. В отличие от оригинальной базы данных MIMIC, сбор биологических сигналов осуществлялся в основном автоматизированным способом. Записи физиологических сигналов в этой базе данных содержат до восьми одновременно записанных сигналов, оцифрованных с частотой 125 Гц. Определенный сигнал или часть сигнала может быть недоступна на протяжении всей записи. Создатели данной базы обработали записи таким образом, чтобы уменьшить вероятность того, что любая запись содержала данные от нескольких пациентов. Данная ситуация возникает из-за особенностей автоматизации процесса сбора и архивирования данных. Также несмотря на то, что сигналы электрокардиограммы с разных каналов были выровнены по времени друг с другом, между любыми другими сигналами может существовать изменяющаяся задержка до 500 мс. Таким

образом, время прибытия импульса PAT, измеренное между зубцом R на электрокардиограмме и систолической точкой фотоплетизмограммы, может быть ненадежным (как в абсолютном, так и в относительном выражении). Кроме того, из-за особенностей масштабирования сигнала электрокардиограммы, не рекомендуется применять некоторые алгоритмы анализа сигнала ЭКГ.

В настоящее время идет разработка следующей версии набора данных MIMIC IV [42]. Сейчас доступно 200 записей от 198 пациентов. Предстоящий выпуск планирует включать около 10 000 записей. В частности, для данной версии решается проблема ошибочного объединения нескольких пациентов в одну запись, а также идентификации сигналов и объединения с клиническими данными пациентов отделений интенсивной терапии.

В 2015 году был опубликован набор данных UCI (University of California Irvine Machine Learning Repository - Репозиторий машинного обучения Калифорнийского университета в Ирвине), который представляет собой отфильтрованную и обработанную версию базы данных волновых сигналов MIMIC II Waveform Database [18], [43]. Набор данных UCI содержит 12000 записей одновременных сигналов фотоплетизмограммы, инвазивного артериального давления и одного канала электрокардиограммы с частотой дискретизации 125 Гц . В описании данного набора не уточняется информация по количеству пациентов, соответствующим записям. При создании набора данных авторы выполнили ряд задач по обработке сигналов, таких как сглаживание с помощью простого усредняющего фильтра, удаление сигналов с неприемлемыми для человека значениями артериального давления и частоты сердечных сокращений, удаление сигналов с сильными разрывами в данных. Основной целью создания данного набора данных является получение чистых и достоверных сигналов для разработки неокклюзионных алгоритмов оценки артериального давления.

Другим широко используемым открытым набором данных является Vital Signs Dataset [45]. Набор данных Vital Signs Dataset Квинслендского

университета содержит широкий спектр данных мониторинга пациентов и жизненно важных показателей, которые были зарегистрированы во время 32 хирургических операций, проводившихся под наркозом в Королевской больнице Аделаиды, в том числе включающий записи сигналов фотоплетизмограммы с частотой 100 Гц, а также неинвазивные значения артериального давления. Основной целью создания данного набора было получение набора многопараметрических данных о жизненных показателях пациентов, находящихся под различными видами анестезии.

Для настоящего исследования было принято решение использовать набор данных UCI на основе данных набора MIMIC II, который включает большое количество синхронизированных записей необходимых сигналов фотоплетизмограммы и инвазивного артериального давления для пациентов интенсивной терапии, с широким диапазоном значений систолического и диастолического артериального давления. По причине выполненной авторами предварительной обработки и очистки сигналов, данные этапы не повторяются. Тем не менее, для дальнейших исследований наиболее перспективным является использование разрабатываемой в настоящее время базы данных MIMIC IV с возможной синхронизацией с клинической частью базы данных и использованием физиологических параметров пациентов наряду с характеристиками биологических сигналов.

1.4 Выводы и направление дальнейшего исследования

В настоящее время для решения задачи определения артериального давления наиболее перспективными являются неокклюзионные методы, которые не требуют использования манжеты при измерении с остановкой кровотока и позволяют производить оценку АД непрерывным способом. Среди неокклюзионных методов наиболее популярными являются методы на основе параметров биологических сигналов, которые характеризуют движение крови в артериях. В частности, методы на основе времени прибытия пульсовой

волны (PAT, у некоторых авторов PTT), для которого требуются сигналы электрокардиограммы и фотоплетизмограммы, а также с использованием скорости распространения пульсовой волны (PWV). В последнее время исследователями для задачи оценки артериального давления все чаще применяются методы машинного обучения с использованием признаков биологических сигналов, а также физиологических признаков пациентов. Привлекательным методом является анализ пульсовой волны (PWA), который подразумевает обработку и извлечение определенных характеристик из фотоплетизмограммы, поскольку для оценки артериального давления требуется только один датчик.

Рассмотренные исследования по задаче определения артериального давления с помощью характеристик сигнала фотоплетизмограммы методами машинного обучения указывают на перспективу развития данного направления, поскольку некоторые результаты по заявлению авторов соответствуют стандарту Ассоциации развития медицинского оборудования AAMI. Тем не менее, важно обращать внимание на размер выборки данных, а также на диапазон значений артериального давления. Например, в некоторых исследованиях набор данных формируется для здоровых добровольцев, что может ограничивать применение данной модели для пациентов отделений интенсивной терапии. Также у многих исследователей для оценки результатов используется метрика средней ошибки ME, которая не является информативной из-за вероятной компенсации положительных и отрицательных значений ошибок. Другие авторы используют абсолютную среднюю ошибку MAE. Дело в том, что в описании стандарта AAMI не уточняется тип средний ошибки. Отдельное внимание стоит уделять количеству записей и соответствующего им количества пациентов во время оценки производительности моделей. В некоторых исследованиях продолжительные записи были разбиты на окна, так что во время обучения моделей и в процессе валидации могли быть использованы разные окна сигналов или даже отдельные фазы сигналов для одних и тех же пациентов.

Среди рассмотренных исследований наиболее популярными моделями машинного обучения являются линейная регрессия, метод опорных векторов, модификации полносвязной нейронной сети. В большинстве работ авторы используют морфологические признаки сигнала фотоплетизмограммы с возможными дополнительными признаками.

В качестве набора данных используется либо набор, подготовленный специально для исследования (в основном здоровые добровольцы), либо используются сигналы открытых баз данных (в основном одна из версий базы MIMIC с данными пациентов отделений интенсивной терапии). С одной стороны, специально собранная база данных позволяет получить биологические сигналы с использованием однотипных датчиков регистрации биологических сигналов, а также физиологические данные пациентов. С другой стороны, открытые базы биологических сигналов представляют большой и разнообразный объем данных с широким диапазоном значений артериального давления.

Для настоящего исследования был выбран набор данных UCI на основе данных набора MIMIC II, который включает синхронизированные записи сигналов фотоплетизмограммы и инвазивного артериального давления для пациентов интенсивной терапии. Используя данный набор, планируется применить и сравнить несколько моделей машинного обучения (линейная регрессия, метод опорных векторов, модель на основе деревьев решений) для оценки значений систолического и диастолического артериального давления, на основе признаков сигнала фотоплетизмограммы. Учитывая различные условия регистрации сигналов ФПГ со множества мониторов пациента в отделении интенсивной терапии при создании базы данных MIMIC II, принято решение не использовать амплитудные характеристики сигнала фотоплетизмограммы. В описании базы данных MIMIC II не указан тип регистрирующего устройства, соответственно, учитывая различную чувствительность датчиков фотоплетизмограммы, амплитудные характеристики сигнала являются неинформативными. В качестве признаков

сигнала фотоплетизмограммы, учитывая проанализированные научные работы, планируется исследовать морфологические признаки, признаки вариабельности сердечного ритма, а также частотные признаки. В качестве метрик для оценки производительности используемых моделей выбрана средняя абсолютная ошибка MAE со средним стандартным отклонением STD, а также коэффициент детерминации R2. С помощью инструментов для интерпретации моделей машинного обучения планируется провести анализ значимости признаков, а также процесса принятия решения моделями.

Таким образом, будет разработан прототип алгоритма машинного обучения для определения систолического и диастолического артериального давления на основе сигнала фотоплезмограммы. В соответствии с полученными результатами будет проведет анализ интерпретируемости модели.

2 Используемые данные, методы и метрики исследования

2.1 Описание используемого набора данных

Для настоящего исследования был использован набор данных UCI, который включает синхронизированные записи сигналов ФПГ и инвазивного АД с частотой дискретизации 125 Гц для пациентов отделений интенсивной терапии [43]. В описании данного набора не уточняется информация по количеству пациентов, соответствующим записям. При создании набора данных авторы выполнили ряд задач по обработке сигналов, таких как сглаживание с помощью простого усредняющего фильтра, удаление сигналов с неприемлемыми для человека значениями артериального давления и частоты сердечных сокращений, удаление сигналов с сильными разрывами в данных. Тем не менее, несмотря на выполненную авторами обработку сигналов, встречаются артефакты сигналов ФПГ и инвазивного АД. Из-за сложного и разнообразного характера артефактов для очистки набора данных рекомендуется визуальный контроль каждого сигнала и ручная очистка набора данных от артефактов, что не входит в задачи данного исследования.

Всего данный набор содержит 12000 записей и поделен на 4 части по 3000 записей, которые хранятся в формате .mat. Для преобразования данного формата в табличный формат была использована библиотека mat73. Из первой части данного набора было выбрано 2265 записей с длительностью более 30 с. Из каждой записи были выбраны первые 30 с сигнала инвазивного АД и сигнала ФПГ, что соответствует первым 3750 точкам сигнала или сэмплам, промежутки времени между которыми являются равными. На рисунке 3 приведен пример сигнала ФПГ и инвазивного АД.

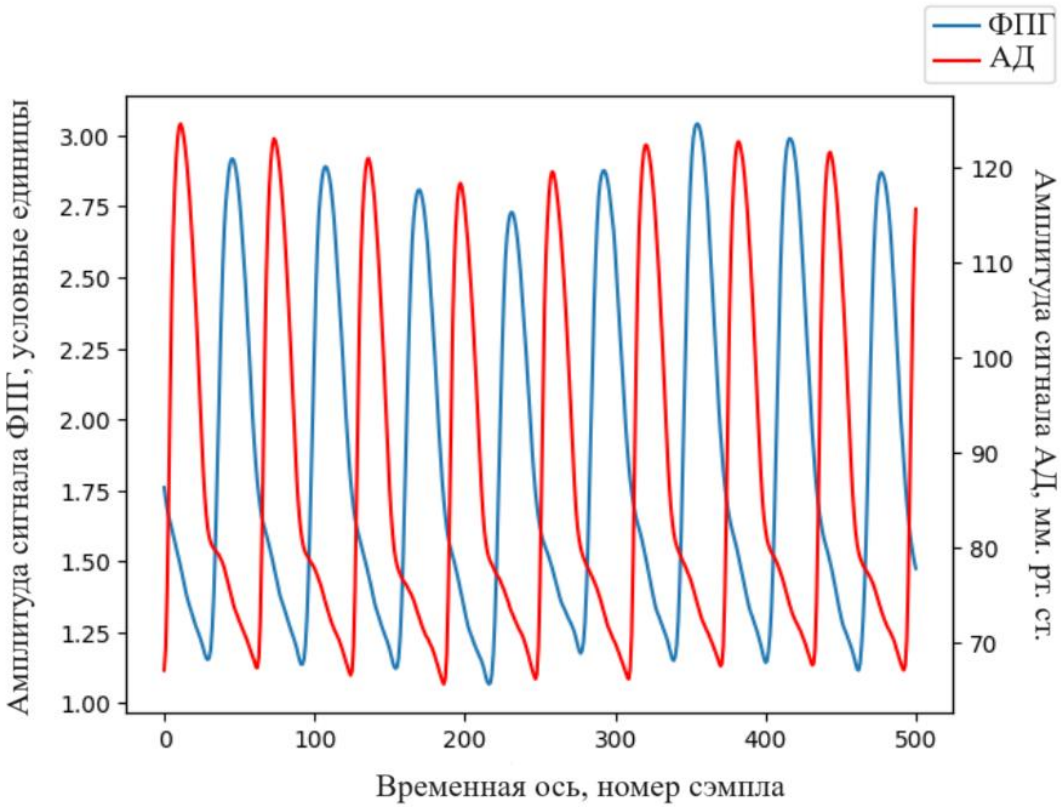

Рисунок 3 – Пример сигнала ФПГ и инвазивного АД

2.2 Последовательность этапов исследования

В соответствии с целю настоящего исследования разработать прототип алгоритма машинного обучения для определения систолического и диастолического АД с использованием признаков сигнала ФПГ, требуется выполнить несколько последовательных этапов.

Прежде всего, необходимо извлечь из сигнала инвазивного АД целевые показатели, а именно значения систолического и диастолического АД. Данные значения извлекаются из усредненной эпохи 30 с сигнала инвазивного АД, где максимальное значение амплитуды соответствует систолическому АД, а минимальное значение амплитуды соответствует диастолическому АД.

Также необходимо извлечь признаки сигала ФПГ, на основании которых будет происходить оценка АД. В зависимости от типа признаков извлечение происходит либо из усредненной эпохи 30 с сигнала ФПГ, либо из

оригинального 30 с сигнала ФПГ. В качестве признаков сигнала ФПГ планируется исследовать:

– временные морфологические признаки усредненной эпохи 30 с сигнала ФПГ (время до и после систолического пика, а также отношение данных времен на разных уровнях амплитуды сигнала),

– признаки вариабельности сердечного ритма (ВСР) для 30 с сигнала ФПГ (набор признаков из библиотеки NeuroKit2 для интервального анализа сигнала ФПГ),

– частотные признаки для 30 с сигнала ФПГ (относительная мощность сигнала в заданной полосе частот с шагом 0.625 Гц или более в диапазоне от 0 до 12.5 Гц).

Для предсказания значений АД требуется решить задачу регрессии с использованием отдельных моделей машинного обучения для систолического и диастолического АД соответственно. В качестве моделей машинного планируется применить:

– линейную регрессию,

– метод опорных векторов (SVM),

– модель градиентного бустинга на основе деревьев решений CatBoost.

В качестве метрик для оценки производительности моделей машинного планируется рассмотреть:

– среднюю абсолютная ошибку (MAE),

– стандартное отклонение абсолютной ошибки (STD),

– коэффициент детерминации (R2).

Метрики планируется оценить на тестовой части записей набора данных, которая составит 20% от первоначальной выборки.

На рисунке 4 приведена схема последовательных этапов настоящего исследования. Выполнение обозначенных этапов проводится в программной среде с созданием кода на языке Python.

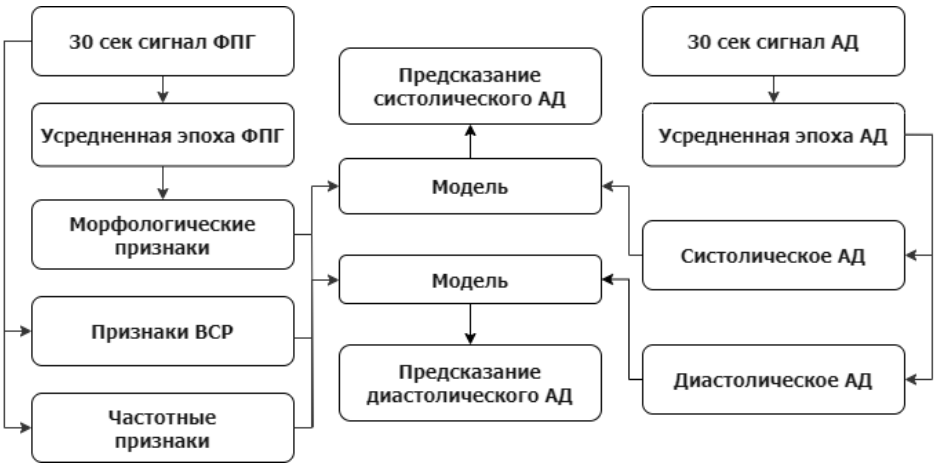

Рисунок 4 – Схема формирования признаков и целевой переменной

Таким образом, планируется разработать и оценить производительность нескольких моделей машинного обучения, отдельно для систолического и диастолического АД. В качестве признаков для моделей машинного обучения используются три группы признаков 30 с сигнала ФПГ (морфологические признаки, признаки ВСР, частотные признаки). В качестве целевых показателей используются максимальное и минимальное значение амплитуды усредненной эпохи 30 с сигнала инвазивного АД для оценки систолического и диастолического АД соответственно.

2.3 Извлечение целевых показателей систолического и диастолического АД

Сигнал инвазивного АД имеет колебательный характер, который непосредственно связан с периодическим сокращением сердца. Максимальное значение амплитуды соответствует систолическому АД, в то время как минимальное значение амплитуды соответствует диастолическому АД.

Для извлечения значений систолического и диастолического АД использовалась библиотека NeuroKit2. Сначала сигнал инвазивного АД длительностью 30 с разбивается на отдельные эпохи с помощью функции ppg_segment, затем получается усредненная эпоха с помощью функции epochs_average. Затем из усредненной эпохи были получены значения

максимальной и минимальной амплитуды с помощью функций min и max, которые принимаются за систолическое и диастолическое АД соответственно (рисунок 5).

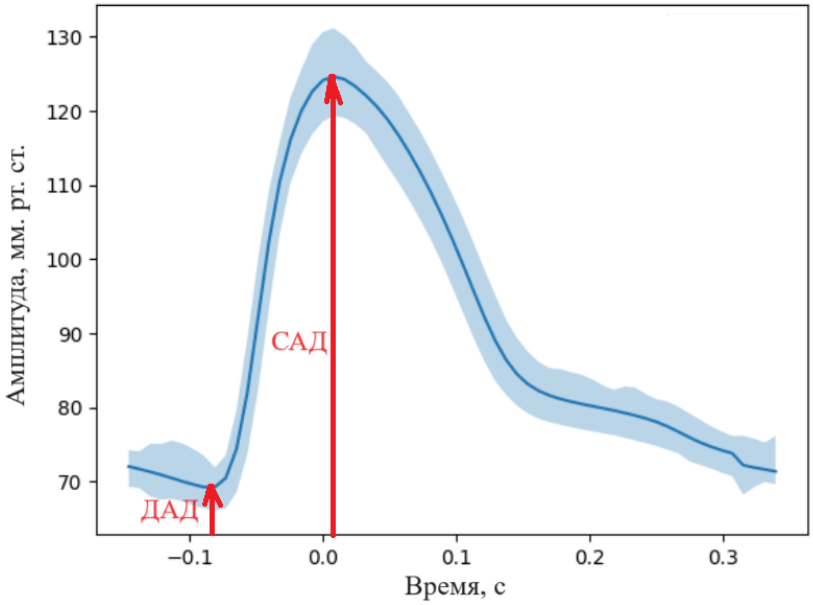

Рисунок 5 – Извлечение значений систолического и диастолического АД из усредненной эпохи сигнала инвазивного АД

Таким образом, для выбранного набора записей диапазон систолического АД составил 70.7–194.4 мм. рт. ст., диапазон диастолического АД составил 50.7–141.0 мм. рт. ст. Значения АД по квартилям 25/50/75% составляют: систолическое 112.2/129.5/147.8 мм. рт. ст., диастолическое 57.8/63.9/72.3 мм. рт. ст. Диаграммы распределений значений систолического и диастолического АД представлены на рисунках 6 и 7 соответственно.

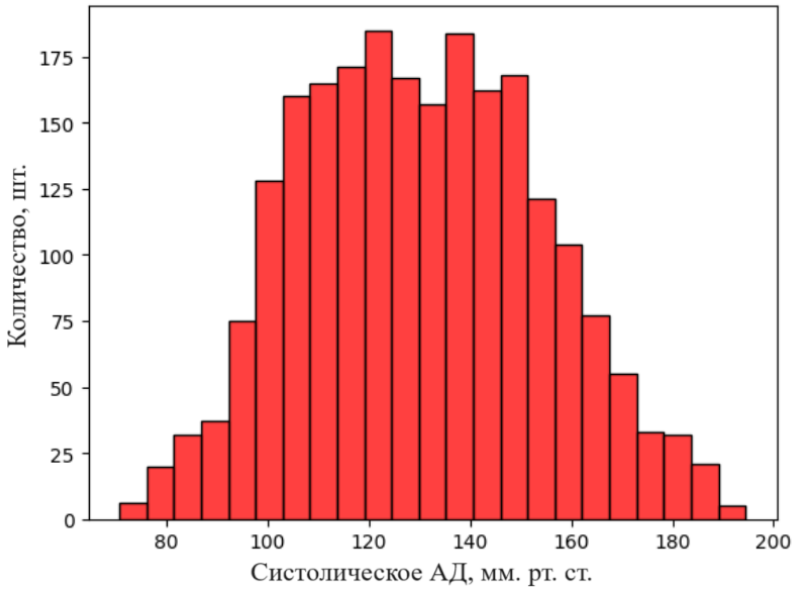

Рисунок 6 – Распределение значений систолического АД

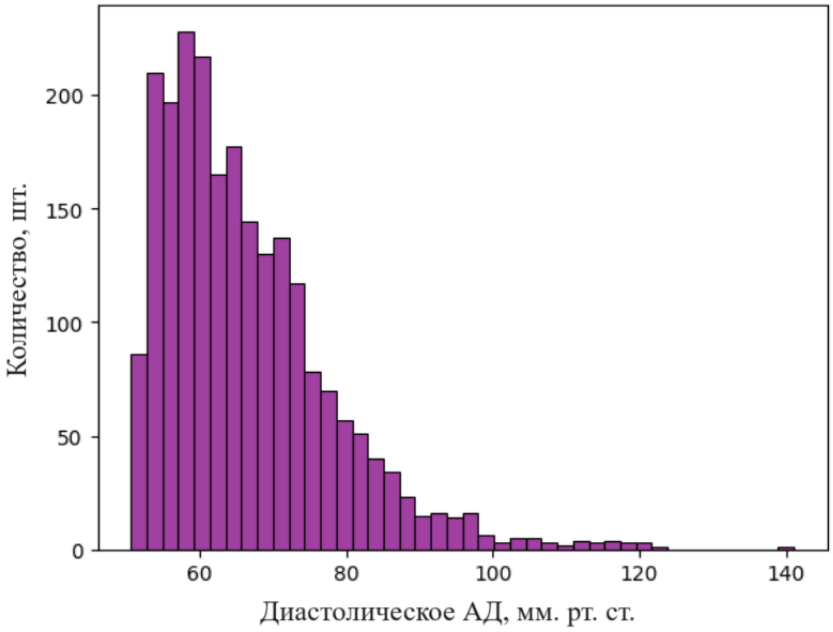

Рисунок 7 – Распределение значений диастолического АД

2.4 Извлечение морфологических признаков сигнала ФПГ

Сигнал ФПГ является одним из биологических сигналов, который характеризует движение крови по артериям. Морфологические временные признаки сигнала ФПГ применяются в большинстве исследований, рассмотренных в первой главе. Учитывая условия регистрации сигналов ФПГ

от различных датчиков ФПГ и их расположения, а также различных мониторов пациента, использованных при формировании набора данных, амплитудные морфорологические характеристики сигнала ФПГ не используются.

Для извлечения морфологических признаков использовалась библиотека NeuroKit2. Сначала для сигнала ФПГ длительностью 30 с применялась дополнительная рекомендованная авторами библиотеки очистка с помощью функции ppg_clean. Затем очищенный сигнал разбивался на отдельные эпохи с помощью функции ppg_segment. Далее была получена усредненная эпоха помощью функции epochs_average. Следующим шагом из усредненной эпохи были получены временные морфологические признаки, которые представляют собой характеристики фаз усредненной эпохи ФПГ до и после систолического пика:

– временные интервалы до и после систолического пика,

– временные интервалы до и после систолического пика на уровнях амплитуды усредненной эпохи сигнала 25%, 33%, 50%, 66%, 75%,

– отношения временного интервала до систолического пика к временному интервалу после систолического пика,

– отношения временного интервала до систолического пика к временному интервалу после систолического пика на уровнях амплитуды усредненной эпохи сигнала 25%, 33%, 50%, 66%, 75%.

Для определения указанных значений временных морфологических признаков были созданы специальные функции, которые используют необходимую часть усредненной эпохи по индексам, соответствующим нужному условию.

На рисунке 8 приведена иллюстрация извлеченных временных морфологических признаков на примере временных интервалов до систолического пика, рассчитанных от точки с минимальной амплитудой сигнала, на разных уровнях амплитуды усредненной эпохи сигнала ФПГ.

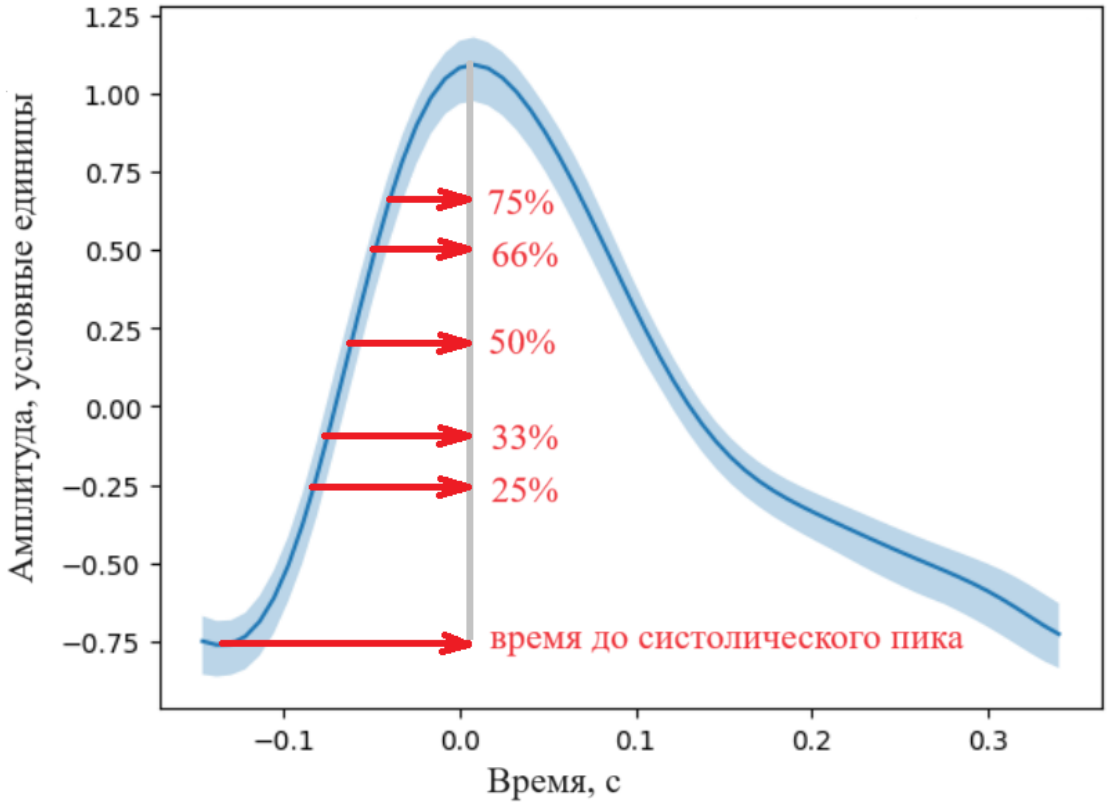

Рисунок 8 – Временной интервал до систолического пика на разных уровнях амплитуды усредненной эпохи сигнала ФПГ

2.5 Извлечение признаков вариабельности сердечного ритма сигнала ФПГ

Характеристики вариабельности сердечного ритма являются значимыми показателям функционирования сердечной деятельности [1]. Отмечается связь между параметрами ВСР и артериальным давлением в работах [2], [20]. Для вычисления параметров ВСР по сигналу ФПГ была использована библиотека NeuroKit2, которая включает встроенный пакет для анализа сигнала ФПГ. На рисунке 9 приведена иллюстрация применения метода ppg_process к 30 с сигналу ФПГ.

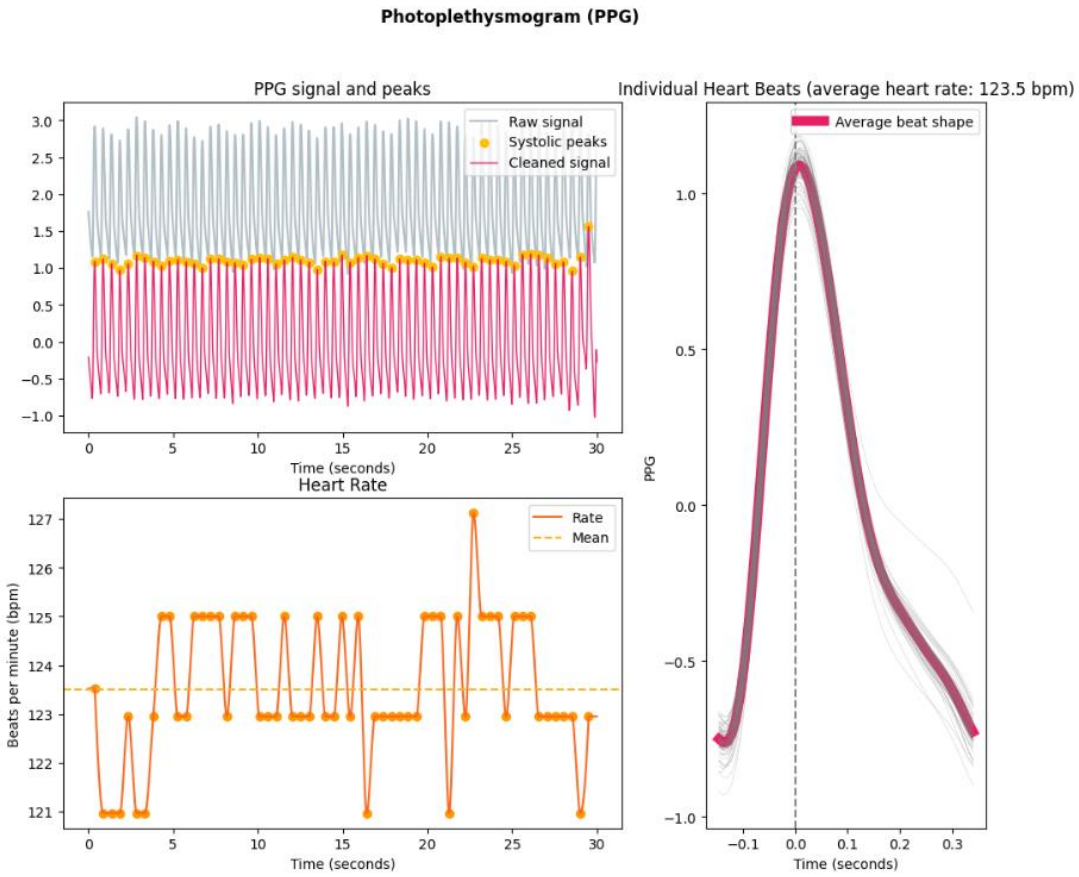

Рисунок 9 – Графики для анализа сигнала ФПГ при применении метода ppg_process библиотеки NeuroKit2

Метод анализа сигнала ФПГ ppg_process включает в себя три основных графика:

– график сигнала ФПГ с отмеченными систолическими пиками (серым цветом отмечен оригинальный сигнал, красным цветом отмечен очищенный сигнал, желтыми точками отмечены систолические пики),

– график частоты сердечных сокращений (оранжевый график соответствует тренду изменения частоты сердечных сокращений, пунктирная линия соответствует среднему значению частоты сердечных сокращений),

– график усредненной фазы сигнала ФПГ.

Для сигналов ФПГ длительностью более 10 с авторы библиотеки рекомендуют проводить интервальный анализ с помощью функции ppg_intervalrelated, которая возвращает среднюю частоту сердечных сокращений, а также набор из 91 различного признака ВСР сигнала ФПГ. Данный набор включает временные показатели ВСР, такие как среднее и

медианное значение временного интервала между соседними систолическими пиками ФПГ, а также разнообразные статистические показатели. Кроме временных показателей, набор признаков включает показатели ВСР в частотной области, такие как мощность на различных диапазонах частот. Дополнительно вычисляются нелинейные показатели ВСР с соответствующим набором статистических параметров, которые включают в себя характеристики графика Пуанкаре (графическое представление каждого интервала RR по отношению к предыдущему интервалу RR), а также индексы энтропии и фрактальной размерности. Среди нелинейных показателей ВСР, относящимся к энтропии и фрактальной размерности, можно отметить фрактальную размерность Хигучи для оценки фрактальной размерности временного ряда, энтропию Шеннона для оценки меры неопределенности для временного ряда, показатель максимального колебания сигнала по мультифрактальному флуктуационному анализу относительно тренда для оценки меры максимальной флуктуации временного ряда.

Полный перечень вычисляемых признаков ВСР сигнала ФПГ доступен в документации библиотеки NeuroKit2 [44].

Для настоящего исследования с целью извлечения признаков ВСР для сигнала ФПГ длительностью 30 с применялась функция ppg_process, а затем к полученному сигналу применялась функция ppg_intervalrelated. Таким образом, было получено 83 признака. Для 11 из полученных 83 признаков отсутствовали значения для всех сигналов ФПГ, соответственно, данные признаки в дальнейшем не рассматривались.

2.6 Извлечение частотных признаков сигнала ФПГ

Одним из наиболее популярных амплитудно-частотных методов анализа биологических сигнала является спектральный анализ, который позволяет оценить спектральную плотность мощности сигнала. Спектральная плотность мощности представляет собой распределение мощности сигнала по

различным частотам и позволяет определить, какая часть мощности сигнала сосредоточена в определенных частотных диапазонах. Анализ спектральной плотности мощности позволяет выделить основные частоты, которые присутствуют в сигнале, а также оценить их вклад в общую мощность сигнала.

В настоящем исследовании для определения спектральной плотности мощности использовался метод signal_power библиотеки NeuroKit2, который позволяет вычислять и визуализировать мощность сигнала в заданном диапазоне частот. На рисунке 10 приведена иллюстрация применения метода signal_power для сигнала ФПГ длительностью 30 с.

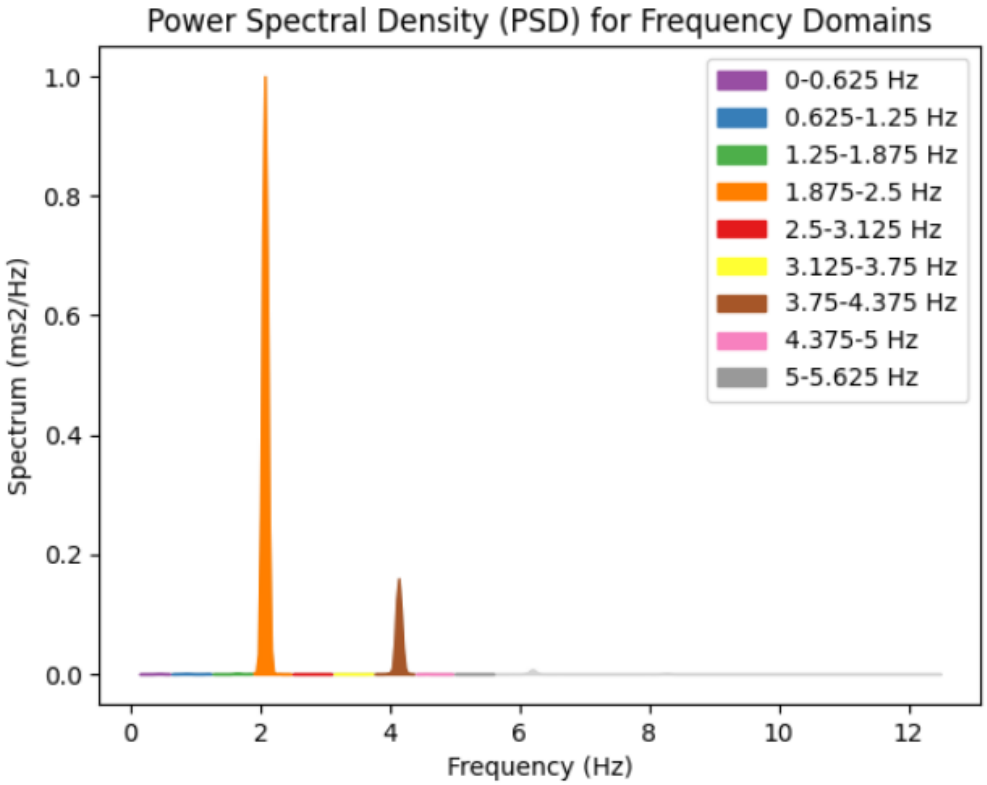

Рисунок 10 – График спектральной плотности мощности сигнала ФПГ в диапазоне частот от 0 до 12.5 Гц с разбиением на линейные интервалы по частотам

Для спектрального анализа сигнала ФПГ был рассмотрен диапазон частот от 0 до 12.5 Гц, который был разделен на 20 равных полос частот с шагом 0.625 Гц. Для каждой такой полосы частот с помощью метода signal_power вычислялась мощность сигнала соответствующего диапазона.

Далее вычислялась и впоследствии применялась относительная величина вклада мощности определенного диапазона к суммарной мощности диапазона частот от 0 до 12.5 Гц.

В соответствии с рекомендациями учебного пособия [1], помимо линейных интервалов были также рассмотрены три нелинейных интервала, которые составили следующие диапазоны частот: от 0.0375 до 0.5 Гц, от 0.5 до 1.875 Гц, от 1.875 до 5 Гц. Аналогичным образом с помощью метода signal_power вычислялась мощность сигнала соответствующего диапазона. Далее вычислялась и впоследствии применялась относительная величина вклада мощности определенного диапазона к суммарной мощности диапазона частот от 0 до 5 Гц. На рисунке 11 приведена иллюстрация применения метода signal_power для сигнала ФПГ длительностью 30 с для диапазона частот от 0 до 5 Гц с разбиением на нелинейные диапазоны.

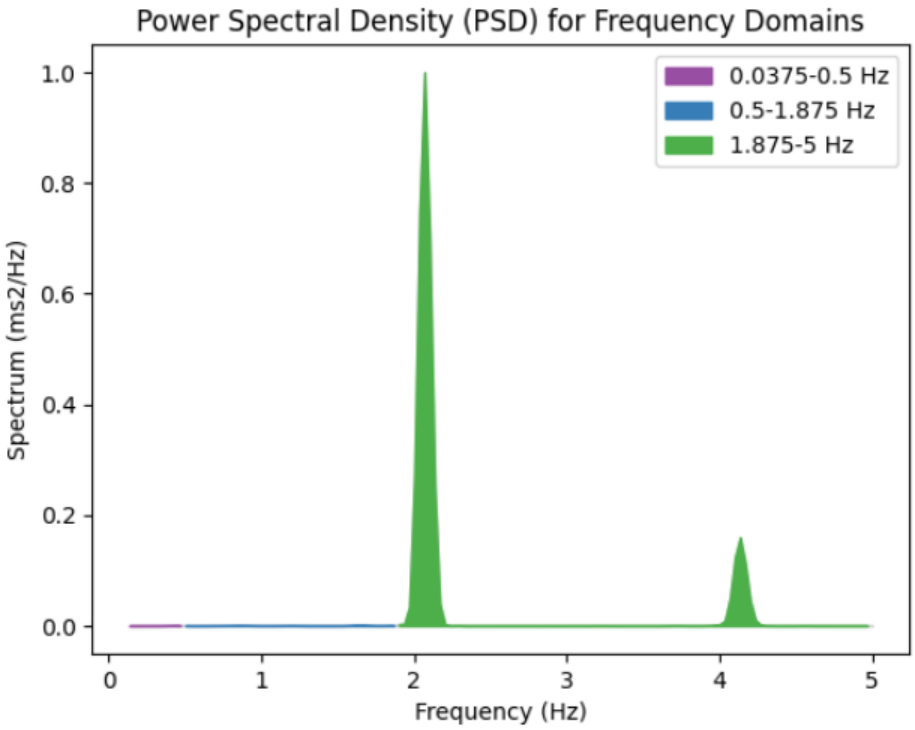

Рисунок 11 – График спектральной плотности мощности сигнала ФПГ в диапазоне частот от 0 до 5 Гц с разбиением на нелинейные интервалы по частотам

2.7 Используемые модели машинного обучения

Для оценки значений систолического и диастолического АД необходимо решить задачу регрессии, с использованием отдельных моделей машинного обучения для систолического и диастолического АД соответственно.

В качестве базовой модели машинного была выбрана линейная регрессия, а именно модель SGDRegressor с применением стохастического градиентного спуска библиотеки sklearn. Линейная регрессия является одним из наиболее простых и широко используемых методов в машинном обучении. Основной идеей линейной регрессии является нахождение линейной комбинации входных признаков, которая наилучшим образом объясняет целевую переменную, так что данная модель описывает линейную зависимость. Соответственно, при наличии нелинейных зависимостей между входными признаками и целевой переменной производительность данной модели может быть существенно ниже. Тем не менее, линейная регрессия является простой и интерпретируемой моделью, и часто используется в качестве базовой модели для сравнения с другими применяемыми методами исследования.

В качестве одной из основных моделей машинного обучения был выбран метод опорных векторов (SVM), а именно модель SVR библиотеки sklearn. Основная идея SVM в случае задачи регрессии заключается в построении оптимальной разделяющей гиперплоскости между точками данных с определенным зазором, которая позволяет минимизировать расстояние между зазором и точками данных, которые находятся за пределами полученного зазора, в то время как точки данных внутри зазора не влияют на итоговый прогноз. То есть гиперплоскость с учетом зазора строится таким образом, чтобы минимизировать ошибку предсказания целевой переменной. SVM может работать с данными высокой размерности и благодаря

нелинейным типам ядер позволяет найти сложные нелинейные зависимости. В данном исследовании использовалось ядро радиального типа.

В качестве другой основной модели машинного обучения была выбрана модель градиентного бустинга на основе деревьев решений Catboost, разработанная компанией Яндекс. Градиентный бустинг для задачи регрессии позволяет создавать ансамбли моделей, которые улучшают качество предсказания путем последовательного уменьшения ошибок предыдущих моделей. Благодаря комбинации множества слабых моделей градиентный бустинг обладает высокой точностью прогнозирования. Одним из преимуществ алгоритма Catboost является высокая скорость и эффективность работы, в том числе благодаря использованию симметричных или забывчивых деревьев. Другим важным преимуществом алгоритма Catboost является возможность визуализации значимости входных признаков с помощью метода feature_importance_, которые вносят наибольший или наименьший вклад в принятие решения модели. Оценка значимости признаков является важным инструментом для интерпретации принятия решений модели, а также для выбора входных признаков, используемых моделью.

2.8 Методы для оценки значимости признаков и интерпретации результатов

Выбор используемых признаков для модели машинного обучения является важным этапом в процессе разработки модели, особенно для ситуации с большим количеством признаков. В данном исследовании изначальное общее количество признаков составило 113 признаков, 18 из которых относятся к морфологической группе признаков, 72 признака относятся к группе признаков ВСР, 23 признака относятся к частотной группе признаков. Информативные признаки способствуют обучению модели на основе значимых данных для прогнозирования значений целевой переменной и могут значительно повысить производительность модели, в то время как

избыточные признаки могут привести к переобучению модели, а также увеличить вычислительную сложность модели.

Корректно выбранные признаки способствуют упрощению интерпретируемости модели, поскольку позволяют понять, какие признаки влияют на результат прогнозирования. Интерпретируемость моделей машинного обучения имеет особое значение в сфере медицины, когда возникает необходимость обосновать принятое моделью решение для конкретного пациента или процесс принятия решений алгоритма в целом, в том числе, для проверки адекватности модели.

В настоящее время для оценки значимости признаков доступны разнообразные методы. В настоящем исследовании применяются такие методы, как Feature Importance (перевод с англ. - важность признаков), Permutation Importance (перевод с англ. - перестановочная важность), метод SHAP (SHapley Additive exPlanations, перевод с англ. - аддитивные объяснения Шэпли), а также Partial Dependence (перевод с англ. - частная зависимость).

Метод Feature Importance в модели деревьев решений вычисляется на основе алгоритма построения дерева. Данный метод измеряет, насколько каждый признак вносит вклад в улучшение качества прогнозирования при разделении в узлах деревьев решений. Соответственно, чем больше улучшение качества, тем более важным считается признак. Feature Importance в модели деревьев решений обычно выражается в виде числа от 0 до 1, где 0 - признак не используется в модели, а 1 - признак полностью определяет целевую переменную.

Метод Permutation Importance может применяться к различным типам моделей. Данный метод основан на перестановке значений одного признака и измерении изменения в метрике качества модели. Если при перемешивании значений признака метрика качества модели значительно ухудшается, то этот признак считается важным. Permutation Importance обычно выражается в виде числа, показывающего изменение в метрике качества после перестановки значений признака. Если при перемешивании значений признака метрика

качества модели, наоборот, улучшается, то Permutation Importance данного признака принимает отрицательное значение.

Метод SHAP для объяснения моделей машинного обучения использует концепцию игры с несколькими участниками, роль которых играют входные признаки, и значения Шепли для определения вклада каждого признака в предсказания модели. В начале для базового значения берется предсказание модели для средних значений признаков. Затем происходит оценка, как отклонение значения признака от среднего значения влияет на предсказание модели. Таким образом, сравнивается предсказание модели с базовым значением, которым является предсказанием для среднего значения признака. При этом формируются различные комбинации признаков, с различными значениями. Для вычисления вклада используются значения Шепли, которые обеспечивают справедливое распределение вклада между признаками. Вклады признаков усредняются по всем комбинациям признаков, чтобы получить окончательный вклад каждого признака для данного наблюдения. Однако, из-за требуемого значительного количества вычислений, данным метод является существенно затратным по времени. Метод SHAP включает большое разнообразие графиков различных типов. Для глобальной интерпретируемости наиболее популярным и информативным графиком является скатерограмма. Признаки на скатерограмме отсортированы в порядке значимости. Красным цветом указаны высокие значения признаков, синим цветом – низкие значения признаков, фиолетовым цветом – средние значения признаков. По оси абсцисс указывается степень влияния признака на целевую переменную. Таким образом, можно оценить, как высокие, низкие, средние значения признаков увеличивают (положительные значения степени влияния) или уменьшают (отрицательные значения степени влияния) значение целевой переменной, либо влияние отсутствует, в таком случае точки данных сосредоточены в районе значения степень влияния, равному нулю. Для анализа локальной интерпретируемости популярным является график SHAP типа ‘водопад’. Данный график строится для конкретной точки данных. При

этом указывается среднее значение целевой переменной и предсказанное значение. Цветными указателями помечены отклонения в числах для каждого признака, влияющие на увеличение или уменьшение значения предсказанной целевой переменной относительно среднего значения. Следует отметить, что для конкретной точки данных порядок признаков по значимости может отличаться от скатерограммы для всего набора данных.

Метод Partial Dependence иллюстрирует с помощью графиков, как изменение значения одного признака влияет на предсказание модели, учитывая фиксированные значения остальных признаков. В данном методе для оценки значимости выбирается определенный признак, при этом фиксируются все значения остальных признаков. Значение выбранного признака меняется, при этом оценивается предсказания модели. Затем происходит усреднение результата по всем объектам из выборки. Таким образом, по оси абсцисс откладывается значение признака, по оси ординат откладывается значение предсказания модели. Чем сильнее наклон графика, тем сильнее влияние определенного признака на целевую переменную. Тип графиков с незначительным наклоном или близких к константе свидетельствует о незначительном влиянии признака на целевую переменную либо об отсутствии влияния.

2.9 Метрики для оценки производительности моделей машинного обучения

Для оценки производительности моделей машинного обучения и, соответственно, точности прогнозирования значений артериального давления используются метрики с ориентацией на стандарт AAMI, а именно средняя абсолютная ошибка (MAE) со стандартным отклонением абсолютной ошибки (STD). Требования для медицинского оборудования стандарта AAMI определяют среднюю ошибку не более 5 мм рт. ст. и стандартное отклонение не более 8 мм рт. ст. для оценки систолического и диастолического АД с

размером выборки не менее 85 субъектов. Следует отметить, что в стандарте AAMI в качестве метрики указана средняя ошибка без уточнения расчета именно абсолютной средней величины.

Абсолютная средняя ошибка (MAE) представляет собой среднее значение абсолютных разностей между фактическими и предсказанными значениями. MAE является простой и интуитивно понятной метрикой, которая измеряет среднее по модулю отклонение прогнозов от истинных значений. MAE вычисляется по формуле (1).

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |y_i - \widehat{y_i}|, \quad (1)$$

где MAE – средняя абсолютная ошибка;

n – количество записей в выборке;

i – номер записи;

y_i – истинное значение целевой переменной для записи с номером i;

$\widehat{y_i}$ – предсказанное значение для записи с номером i.

Стандартное отклонение (STD) представляет собой меру разброса значений абсолютных ошибок относительно их среднего значения MAE. Чем больше STD, тем больше разброс значений абсолютных ошибок относительно среднего значения MAE. STD вычисляется по формуле (2).

$$STD = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (|y_i - \widehat{y_i}| - MAE)^2}, \quad (2)$$

где STD – стандартное отклонение,

n – количество записей в выборке;

i – номер записи;

y_i – истинное значение целевой переменной для записи с номером i;

$\widehat{y_i}$ – предсказанное значение для записи с номером i;

MAE – средняя абсолютная ошибка.

В качестве дополнительной метрики для оценки производительности моделей машинного обучения был выбран коэффициент детерминации (R2), который является стандартной метрикой для задач регрессии и характеризует долю объясненной дисперсии. R2 принимает значения не более 1. Чем ближе значение R2 к 1, тем точнее предсказание модели. Значение R2 равное 0 соответствует предсказанию среднего значения прогнозируемой величины. Значение R2 меньше 0 соответствует ситуации, когда модель предсказывает значение прогнозируемой величины хуже, чем среднее значение, и, соответственно, указывает на непригодность применения такой модели. R2 вычисляется по формуле (3).

$$R2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2}, \quad (3)$$

где $R2$ – коэффициент детерминации,

n – количество записей в выборке;

i – номер записи;

y_i – истинное значение целевой переменной для записи с номером i;

$\hat{y}_i$ – предсказанное значение для записи с номером i;

$\bar{y}$ – среднее значение целевой переменной.

3 Полученные результаты и их интерпретация

3.1 Сравнение производительности моделей машинного обучения в соответствии с группами признаков сигнала ФПГ

Для определения систолического и диастолического АД использовались отдельные модели машинного обучения на основе трех групп признаков сигнала ФПГ: морфологических, признаков ВСР и частотных признаков. Для обучения каждой модели использовались как отдельные группы признаков, так все группы признаков одновременно.

Ниже в таблице 2 приведена сравнительная таблица производительности трех моделей машинного обучения с предварительным отбором признаков и выполненной настройкой параметров обучения моделей: линейная регрессия, метод опорных векторов SVM с радиальным ядром, модель градиентного бустинга на основе деревьев решений CatBoost. В качестве метрик выбраны средняя абсолютная ошибка (MAE), стандартное отклонение абсолютной ошибки (STD), коэффициент детерминации (R2). Метрики оценивались на тестовой части набора данных, которая составила 20% от первоначальной выборки. По каждой строке выделен лучший результат по метрике MAE.

Таблица 2 – Производительность моделей машинного обучения в зависимости от группы признаков, MAE ± STD мм. рт. ст./ R2

	Систолическое АД			**Диастолическое АД**		
признаки	**Линейная регрессия**	**SVM**	**CatBoost**	**Линейная регрессия**	**SVM**	**CatBoost**
морфологические	17.5 ± 13.0/ 0.21	13.5±11.5/ 0.48	**13.2 ± 11.5/ 0.49**	8.4 ± 7.8/ 0.09	7.3 ± 7.6/ 0.24	**7.2 ± 7.7/ 0.23**
ВСР	17.3 ± 12.7/ 0.17	16.4±12.8/ 0.22	**16.0 ± 12.8/ 0.25**	8.4 ± 8.0/ 0.15	**7.9 ± 8.1/ 0.19**	8.1 ± 7.9/ 0.20
частотные	17.4 ± 12.9/ 0.16	**13.8±12.1/ 0.40**	14.0 ± 12.2/ 0.38	8.8 ± 8.5/ 0.06	**7.6 ± 8.6/ 0.17**	7.8 ± 8.3/ 0.19
все группы	16.1 ± 12.1/ 0.27	12.7±11.4/ 0.48	**12.3 ± 11.1/ 0.51**	8.0 ± 7.9/ 0.20	7.0 ± 7.7/ 0.32	**6.9 ± 7.6/ 0.33**

Исходя из данной таблицы можно сделать следующие выводы:

1) систолическое АД оценивается точнее, чем диастолическое АД согласно метрике R2,

2) диастолическое АД имеет меньшее значение MAE и STD, чем систолическое АД,

3) для оценки систолического АД наиболее информативными являются морфологические признаки,

4) для оценки систолического АД модель CatBoost показала лучшую производительность с использованием всех групп признаков с результатом MAE ± STD равным 12.3 ± 11.1 мм. рт. ст. и R2 равным 0.51,

5) Для оценки диастолического АД модель CatBoost показала лучшую производительность с использованием всех групп признаков с результатом MAE ± STD равным 6.9 ± 7.6 мм. рт. ст. и R2 равным 0.33.

3.2 Значимость признаков и интерпретация полученных результатов модели для оценки систолического АД

С помощью методов оценки значимости признаков и интерпретации результатов работы моделей машинного обучения была проанализирована модель CatBoost для определения систолического АД, которая показала лучший результат MAE ± STD равный 12.3 ± 11.1 мм. рт. ст. и R2 равный 0.51. В данной модели было использовано 62 признака, 27 из которых относятся к признакам ВСР, 17 признаков относятся к частотным признакам и 18 признаков относятся к морфологическим признакам. Полный список используемых признаков с расшифровкой указан в Приложении А.

На рисунке 12 представлен график Permutation Importance для 15 наиболее значимых признаков модели, 9 из которых относятся к морфологической группе, 6 из которых относятся к частотной группе признаков.

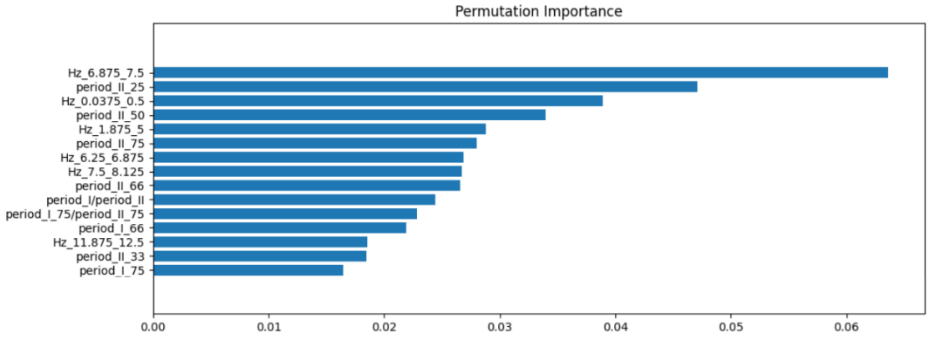

Рисунок 12 – График Permutation Importance для модели CatBoost для оценки систолического АД

Наиболее важными морфологическими признаками согласно методу Permutation Importance являются временные интервалы после систолического

пика на уровне амплитуды сигнала ФПГ 25%, 50% и 75%. Наиболее важными частотными признаками являются относительные мощности сигнала в диапазоне частот от 6.875 до 7.5 Гц, от 0.0375 до 0.5 Гц, от 1.875 до 5 Гц. Наиболее значимым является признак относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц, в то время как условная величина значимости составляет немного более 0.06, что является сравнительно небольшим значением. Таким образом, каждый из признаков вносит относительно небольшой вклад в суммарную производительность модели.

На рисунке 13 представлен график Feature Importance для 15 наиболее значимых признаков модели, 8 из которых относятся к морфологической группе, 7 из которых относятся к частотной группе признаков.

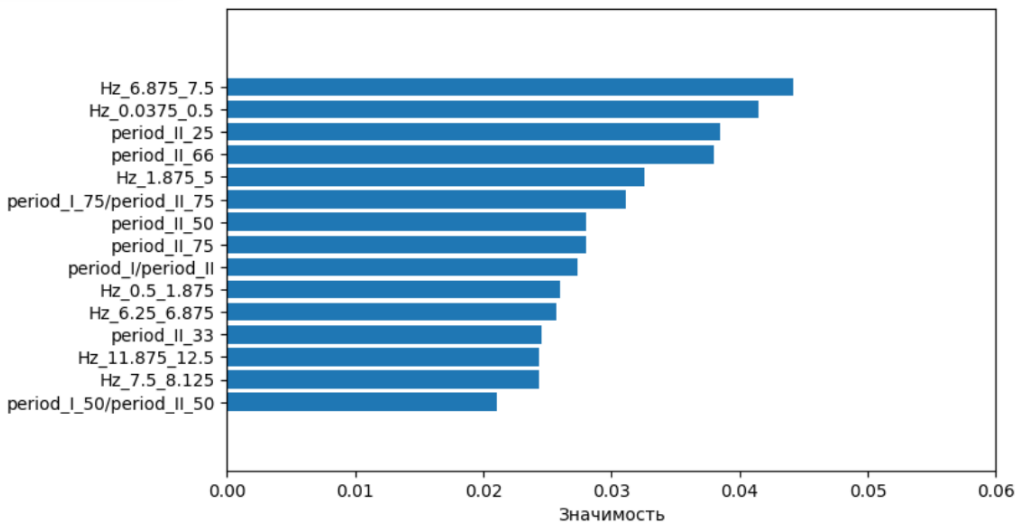

Рисунок 13 – График Feature Importance для модели CatBoost для оценки систолического АД

Наиболее важными морфологическими признаками согласно методу Feature Importance являются временные интервалы после систолического пика на уровне амплитуды сигнала ФПГ 25%, 66% и 75%. Наиболее важными частотными признаками являются относительные мощности сигнала в диапазоне частот от 6.875 до 7.5 Гц, от 0.0375 до 0.5 Гц, от 1.875 до 5 Гц. Наиболее значимым является признак относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7 Гц, в то время как условная величина

значимости составляет менее 0.05, что является сравнительно небольшим значением. Таким образом, каждый из признаков вносит относительно небольшой вклад в суммарную производительность модели.

На рисунке 14 представлена скатерограмма SHAP для 15 наиболее значимых признаков модели, 8 из которых относятся к морфологической группе, 7 из которых относятся к частотной группе признаков.

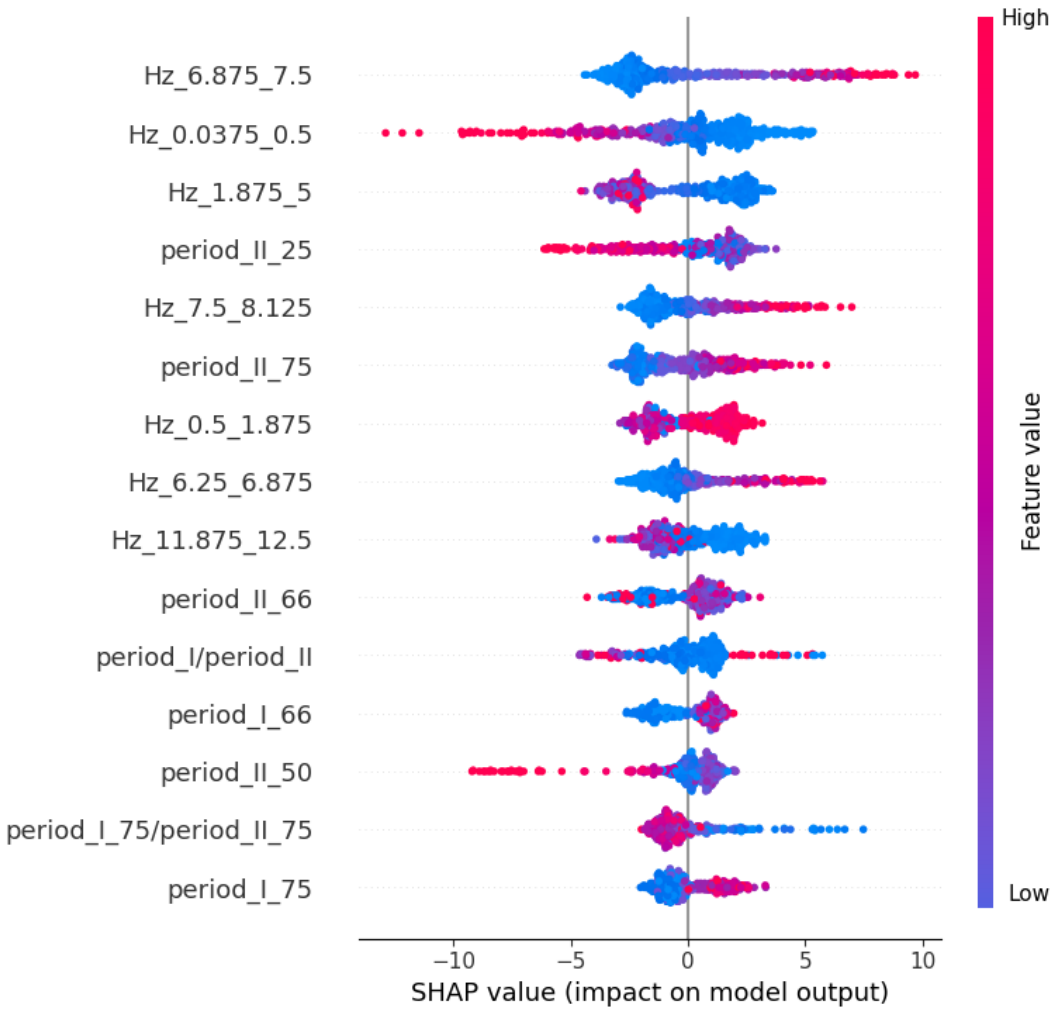

Рисунок 14 – Скатерограмма SHAP для модели CatBoost для оценки систолического АД

Исходя из данной скатерограммы можно сделать вывод о том, что наиболее важными морфологическими признаками являются временные интервалы после систолического пика на уровне амплитуды сигнала ФПГ 25%, 75% и 66%. Наиболее важными частотными признаками являются

относительные мощности сигнала в диапазоне частот от 6.875 до 7.5 Гц, от 0.0375 до 0.5 Гц, от 1.875 до 5 Гц. Наиболее значимым является признак относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц: значения ниже среднего соответствуют более низким значениям систолического АД, средние и выше среднего значения соответствуют более высоким значениям систолического АД. Чем больше значение данного признака, тем сильнее его влияние в сторону прогнозирования более высоких значений. Второй по значимости признак относительной мощности сигнала ФПГ в диапазоне частот от 0.0375 до 0.5 Гц влияет на прогноз модели противоположным образом: значения признаков ниже среднего соответствуют более высоким значениям систолического АД, средние и выше среднего значения соответствуют более низким значениям систолического АД. Чем больше значение данного признака, тем сильнее его влияние в сторону прогнозирования более низких значений. Следующий по значимости признак относительной мощности сигнала ФПГ в диапазоне частот от 1.875 до 5 Гц влияет на целевую переменную схожим предыдущему признаку образом, однако его влияние в сторону прогнозирования более низких и более высоких значений систолического АД более слабое. Значения выше среднего следующего по значимости морфологического признака временного интервала после систолического пика на уровне амплитуды сигнала ФПГ 25% соответствуют более низким значения систолического АД, а средние и ниже среднего значения, наоборот, более высоким значениям систолического АД. Следующие по значимости признаками являются признаки относительной мощности сигнала ФПГ в диапазоне частот от 7.5 до 8.125 Гц и времени после систолического пика на уровне амплитуды сигнала ФПГ 75%. Средними значения и значения выше среднего данных признаков влияют в сторону прогнозирования более высоких значений систолического АД, в то время как значения ниже среднего влияют в сторону прогнозирования более низких значений систолического АД.

В соответствии с представленными графиками можно сделать следующие выводы:

1) для всех трех методов оценки значимости признаков совпадает наиболее значимый признак - относительная мощность сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц,

2) из 15 наиболее значимых признаков 12 признаков совпадают для всех трех методов оценки значимости признаков,

3) наиболее значимыми признаками являются частотные и морфологические признаки.

На рисунке 15 представлены графики PartialDependence с наиболее сильным наклоном и, соответственно, степенью значимости признака

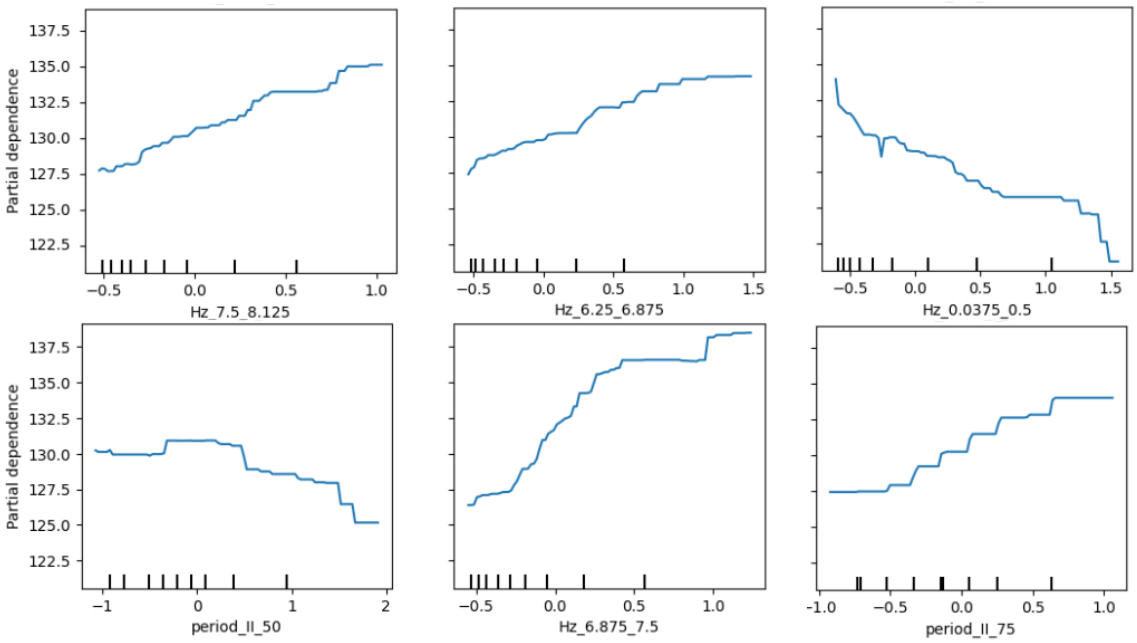

Рисунок 15 – Графики Partial Dependence для признаков с наиболее сильным наклоном для модели CatBoost для оценки систолического АД

В соответствии с данными графиками, можно сделать вывод о том, что значимыми частотными признаками являются признаки относительной мощности сигнала ФПГ в диапазоне частот от 1.875 до 5 Гц, от 7.5 до 8.125 Гц, от 0.0375 до 0.5 Гц, а также от 6.875 до 7.5 Гц. Значимыми морфологическими признаками являются признака временного интервала после систолического

пика на уровнях амплитуды сигнала ФПГ 75% и 50%. На данных графиках тип наклона свидетельствует о прямой или обратной пропорциональной зависимости значений признака и целевой переменной. При сравнении со скатерограммой SHAP отмечается аналогичная зависимость для указанных признаков. Также на некоторых графиках, соответствующим определенным признакам, достаточно сильный наклон наблюдается только на определенном диапазоне значений признака. Данные графики приведены на рисунке 16.

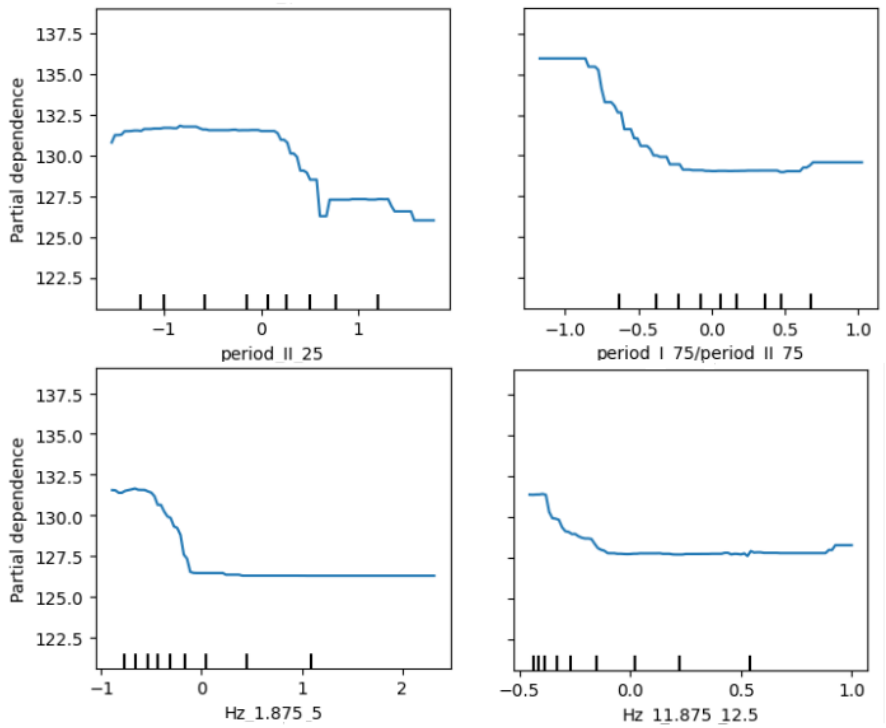

Рисунок 16 – Графики Partial Dependence для признаков с наиболее сильным наклоном на определенном диапазоне значений для модели CatBoost для оценки систолического АД

Таким образом, в особенности для определенного диапазона значений признаков, существенное влияние на предсказание целевой переменной могут оказывать частотные признаки относительной мощности сигнала ФПГ в диапазоне частот от 1.875 до 5 Гц и от 11.875 до 12.5 Гц, а также морфологические признаки временного интервала после систолического пика на уровне амплитуды сигнала ФПГ 25% и отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 75%. При

сравнении со скатерограммой SHAP отмечается аналогичная прямая либо обратно пропорциональная зависимость для указанных признаков с целевой переменной. Следует отменить, что результаты анализа Partial Dependence также согласуются с предыдущими методами анализа Feature Importance и Permutation Importance, поскольку все рассмотренные 9 признаков присутствуют на графиках обоих методов.

В Приложении В приведены графики локальной интерпретируемости SHAP типа ‘водопад’ для конкретных точек данных. На рисунках В.1 и В.2 представлены графики для примера двух точек, разница между предсказанными и истинными значениями которых составляет не более 1 мм рт. ст. Для данных точек часть значимых признаков совпадает с основными значимыми признаками для глобальной интерпретируемости, отмеченными выше. Для примера В.1 это признаки относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц и от 7.5 до 8.125 Гц, а также временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 25%. Для примера В.2 это признаки относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц и от 0.0375 до 0.5 Гц, а также временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 25%. Однако, определенные менее значимые признаки в смысле глобальной интерпретируемости проявляют значимость для данных точек. Для примера В.1 это признак относительной мощности сигнала ФПГ в диапазоне частот от 6.25 до 6.875 Гц, отношение временных интервалов до и после систолического пика. Для примера В.2 это признак относительной мощности сигнала ФПГ в диапазоне частот от 0.625 до 1.25 Гц, а также временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 75%. На рисунке В.1 отмечается основной отрицательный вклад признаков, который приводит к достаточно точному предсказанному значению ниже среднего. Тем не менее, присутствует взаимная компенсация положительных и отрицательных значений для наиболее значимых признаков для данной точки. На рисунке В.2 отмечается основной положительный вклад признаков, который приводит к

достаточно точному предсказанному значению выше среднего. На рисунках В.3 и В.4 представлены графики для примера двух точек, предсказанные значения для которых занижены более чем на 40 мм рт. ст. по сравнению с истинным значением. Аналогично предыдущим точкам, часть значимых признаков совпадает с основными значимыми признаками для глобальной интерпретируемости. Для примера В.3 это признаки относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц и от 0.0375 до 0.5 Гц, а также временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 25%. Для примера В.4 это признаки относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц и от 0.0375 до 0.5 Гц, а также временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 75%. Аналогично менее значимые признаки в смысле глобальной интерпретируемости проявляют значимость для данных точек. Для примера В.3 это признаки относительной мощности сигнала ФПГ в диапазоне частот от 6.25 до 6.875 Гц, от 8.125 до 8.75 Гц. Для примера В.4 это признак максимального интервала между соседними систолическими пиками, а также отношение временных интервалов до и после систолического пика. Для обеих точек можно отметить положительный вклад одних признаков и отрицательный вклад других признаков, соответственно, происходит частичная компенсация суммарного вклада всех признаков. Заниженная ошибка прогнозирования могла возникнуть из-за недостаточного положительного вклада значимых признаков и ошибочной высокой компенсацией отрицательным вкладом других признаков. На рисунках В.5 и В.6 представлены графики для примера двух точек, предсказанные значения для которых завышены более чем на 40 мм рт. ст. по сравнению с истинным значением. Аналогично предыдущим точкам, часть значимых признаков совпадает с основными значимыми признаками для глобальной интерпретируемости. Для примера В.5 это признаки относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц и от 1.875 до 5 Гц. Для примера В.6 это признаки относительной мощности сигнала ФПГ в диапазоне

частот от 0.0375 до 0.5 Гц и от 1.875 до 5 Гц. Аналогично менее значимые признаки в смысле глобальной интерпретируемости проявляют значимость для данных точек. Для примера B.5 это признак отношения временных интервалов до и после систолического пика, а также отношение стандартного отклонения перпендикулярно линии идентичности к стандартному отклонению вдоль лини идентичности для графика Пуанкаре. Для примера B.6 это признак относительной мощности сигнала ФПГ в диапазоне частот от 11.875 Гц до 12.5 Гц, а также признак отношение количества точек ниже линии идентичности к количеству всех точек графика Пуанкаре за исключением точек, лежащих на линии идентичности. На рисунке B.5 можно отметить взаимную компенсацию положительных и отрицательных вкладов признаков, как следствие, ошибочное завышенное значение в районе среднего значения целевой переменной. На рисунке B.6 отмечается основной положительный вклад признаков, который привет к ошибочному завышенному значению.

Таким образом, наиболее значимыми признаками для предсказания систолического АД являются признаки частотной и морфологической группы. Для частных точек существенную значимость могут проявлять также признаки группы ВСР. Тем не менее, итоговый результат предсказания модели формируется сложным образом с учетом множества признаков как суммарный вклад всех признаков, при этом каждый признак вносит свой относительно небольшой вклад в итоговый результат предсказания модели.

3.3 Значимость признаков и интерпретация полученных результатов модели для оценки диастолического АД

С помощью методов оценки значимости признаков и интерпретации результатов работы моделей машинного обучения была проанализирована модель CatBoost для определения диастолического АД, которая показала лучший результат MAE ± STD равным 6.9 ± 7.6 мм. рт. ст. и R2 равным 0.33.

В данной модели было использовано 48 признаков, 20 из которых относятся к признакам ВСР, 10 признаков относятся к частотным признакам и 18 признаков относятся к морфологическим признакам. Полный список используемых признаков с расшифровкой указан в Приложении 2.

На рисунке 17 представлен график Permutation Importance для 15 наиболее значимых признаков модели, 7 из которых относятся к признакам ВСР, 6 признаков относятся к морфологической группе, 2 признака относятся к частотной группе признаков. Наиболее важными признаками ВСР являются величина фрактального измерения Хигучи, треугольный индекс ВСР, показатель максимального колебания сигнала по флуктуационному анализу относительно тренда, 20-й процентиль интервалов между соседними систолическими пиками.

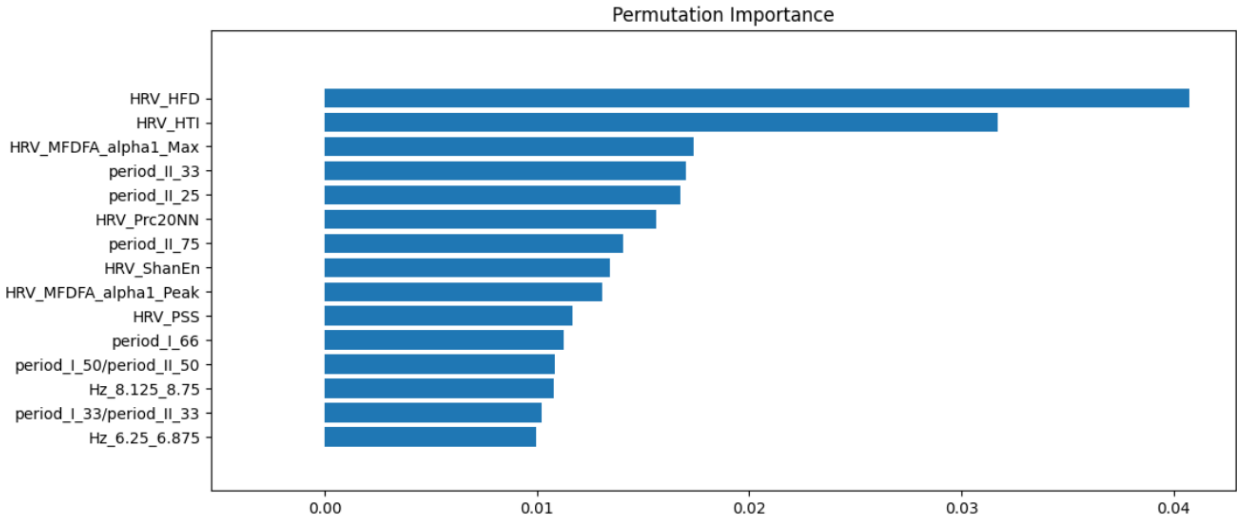

Рисунок 17 – График Permutation Importance для модели CatBoost для оценки диастолического АД

Согласно методу Permutation Importance, наиболее важными признаками ВСР являются величина фрактального измерения Хигучи, треугольный индекс ВСР, показатель максимального колебания сигнала по флуктуационному анализу относительно тренда, 20-й процентиль интервалов между соседними систолическими пиками. Наиболее важными морфологическими признаками

являются временные интервалы после систолического пика на уровне амплитуды сигнала ФПГ 33% и 25%. Наиболее значимым является признаком является величина фрактального измерения Хигучи, в то время как условная величина значимости составляет немного более 0.04, что является сравнительно небольшим значением. Таким образом, каждый из признаков вносит относительно небольшой вклад в суммарную производительность модели.

На рисунке 18 представлен график Feature Importance для 15 наиболее значимых признаков модели, 5 из которых относятся к признакам ВСР, 5 признаков которых относятся к морфологической группе, 5 признаков относятся к частотной группе признаков.

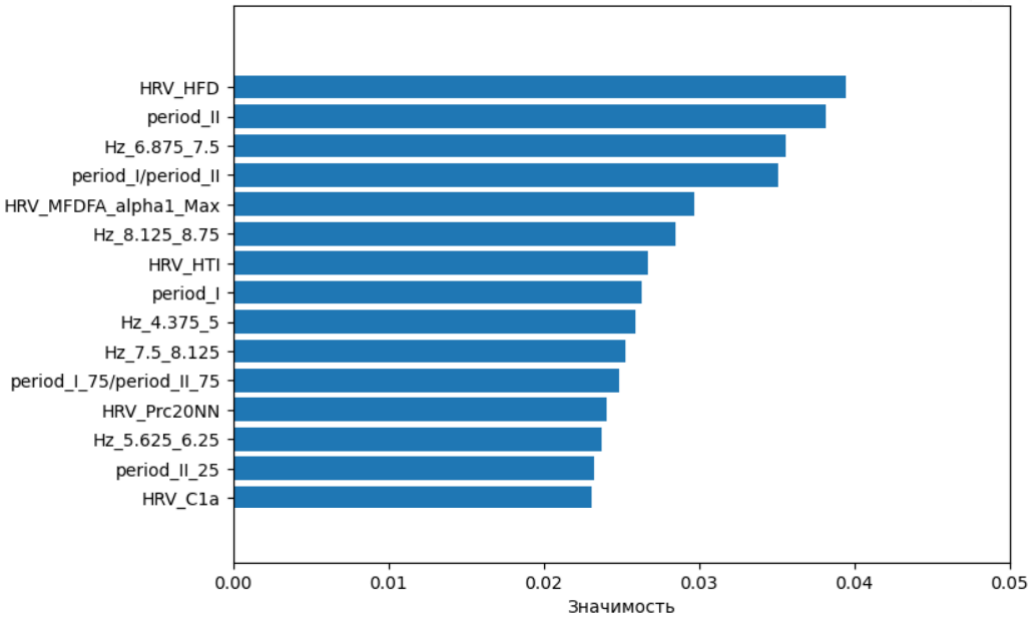

Рисунок 18 – График Feature Importance для модели CatBoost для оценки диастолического АД

Согласно методу Feature Importance, наиболее важными являются из признаков ВСР являются величина фрактального измерения Хигучи и показатель максимального колебания сигнала по флуктуационному анализу относительно тренда, из морфологических признаков - временной интервал после систолического пика и отношение временного интервала до систолического пика к временному интервалу после систолического пика, из

частотных признаков - относительные мощности сигнала в диапазоне частот от 6.875 до 7.5 Гц и от 8.125 до 8.75 Гц. Наиболее значимым признаком является величина фрактального измерения Хигучи, в то время как условная величина значимости составляет немного более 0.04, что является сравнительно небольшим значением. Таким образом, каждый из признаков вносит относительно небольшой вклад в суммарную производительность модели.

На рисунке 19 представлена скатерограмма SHAP для 15 наиболее значимых признаков модели, 5 из которых относятся к морфологической группе, 7 признаков относятся к группе признаков BCP, 3 признака относятся к частотной группе признаков.

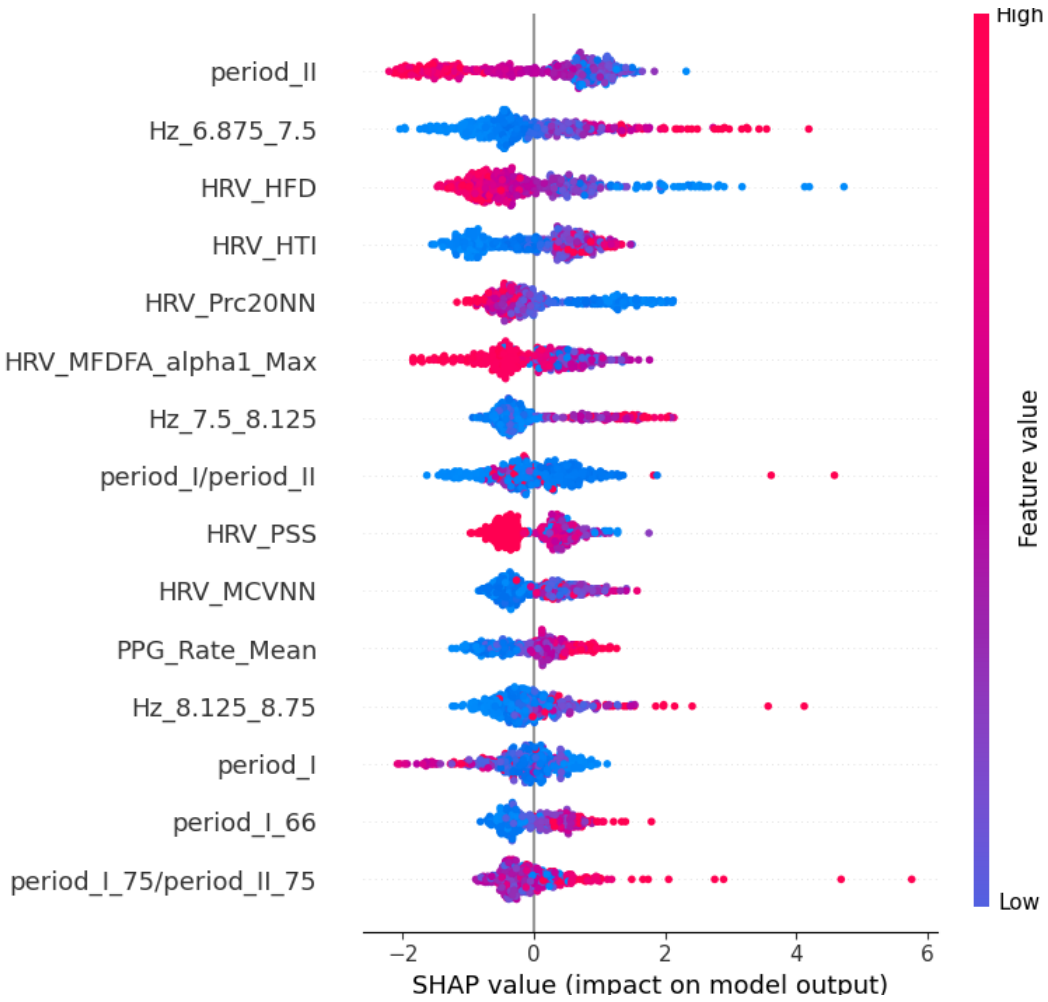

Рисунок 19 – Скатерограмма SHAP для модели CatBoost для оценки диастолического АД

Согласно скатерограмме SHAP, наиболее важными являются морфологический признак временного интервала после систолического пика, частотный признак относительной мощности сигнала в диапазоне частот от 6.875 до 7.5 Гц, а также признаки ВСР: величина фрактального измерения Хигучи, треугольный индекс ВСР, показатель максимального колебания сигнала по флуктуационному анализу относительно тренда, 20-й процентиль интервалов между соседними систолическими пиками. Наиболее значимым является морфологический признак временного интервала после систолического пика: средние значения и значения ниже среднего соответствуют более высоким значениям диастолического АД, в то время как значения выше среднего соответствуют более низким значениям диастолического АД, причем чем больше значение данного признака, тем сильнее его влияние в сторону прогнозирования более низких значений. Второй по значимости признак относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц влияет на прогноз модели противоположным образом: значения признаков ниже среднего соответствуют более низким значениям диастолического АД, средние и выше среднего значения соответствуют более высоким значениям диастолического АД, причем чем больше значение данного признака, тем сильнее его влияние в сторону прогнозирования более высоких значений. Следующий по значимости признак величины фрактального измерения Хигучи ведет себя схожим первому по значению признаку образом, однако его влияние в сторону прогнозирования низких значений более слабое, а для прогнозирования высоких значений диастолического АД, наоборот, более сильное. Следующий по значимости признак треугольный индекс ВСР ведет себя схожим второму по значению признаку образом, однако его влияние в сторону прогнозирования низких и высоких значений диастолического АД более слабое. Значения выше среднего и средние значения следующего по значимости признака 20-го процентиля интервалов между соседними систолическими пиками соответствуют более низким значения

диастолического АД, а значения ниже среднего значения, наоборот, соответствуют более высоким значениям диастолического АД. Следующим по значимости признаков является показатель максимального колебания сигнала по флуктуационному анализу относительно тренда. Основная часть значений выше среднего влияет в сторону прогнозирования более низких значений диастолического АД, в то время как средние значениями и значения ниже среднего влияют в сторону прогнозирования более низких значений диастолического АД.

В соответствии с представленными графиками можно сделать следующие выводы:

1) для двух методов оценки значимости признаков совпадает наиболее значимый признак - величина фрактального измерения Хигучи, который для метода SHAP находится на третьем по значимости месте;

2) из 15 наиболее значимых признаков 5 признаков совпадают для всех трех методов оценки значимости признаков;

3) признаки всех групп являются значимыми для прогнозирования модели, сложно выделить наиболее значимую группу признаков.

На рисунке 20 представлены графики PartialDependence с наиболее сильным наклоном и, соответственно, степенью значимости признака.

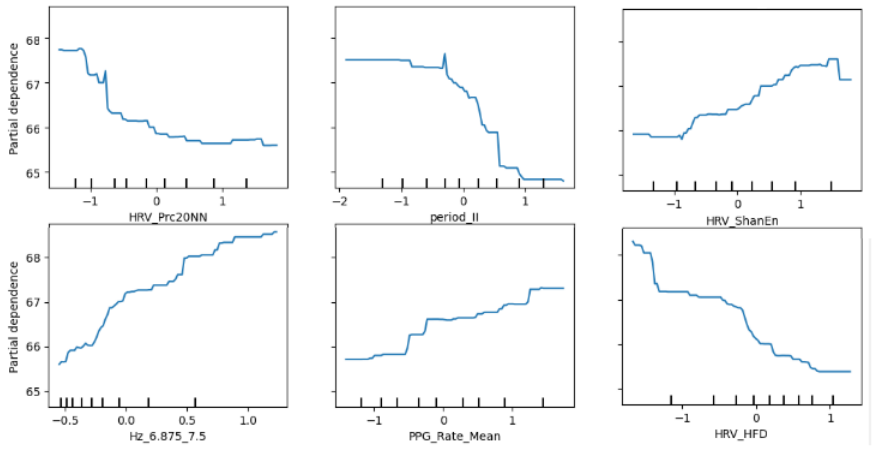

Рисунок 20 – Графики Partial Dependence для признаков с наиболее сильным наклоном для модели CatBoost для оценки диастолического АД

В соответствии с данными графиками, можно сделать вывод о том, что значимыми частотным признаком является относительная мощность сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц. Значимым морфологическим признаком является временной интервала после систолического пика. Значимыми признаками ВСР являются величина фрактального измерения Хигучи, 20-й процентиль интервалов между соседними систолическими пиками, величина энтропии Шеннона, а также средняя частота сердечных сокращений. На данных графиках тип наклона свидетельствует о прямой или обратной пропорциональной зависимости значений признака и целевой переменной. При сравнении со скатерограммой SHAP отмечается аналогичная зависимость для указанных признаков. Также на некоторых графиках, соответствующим определенным признакам, достаточно сильный наклон наблюдается только на определенном диапазоне значений признака. Данные графики приведены на рисунке 21.

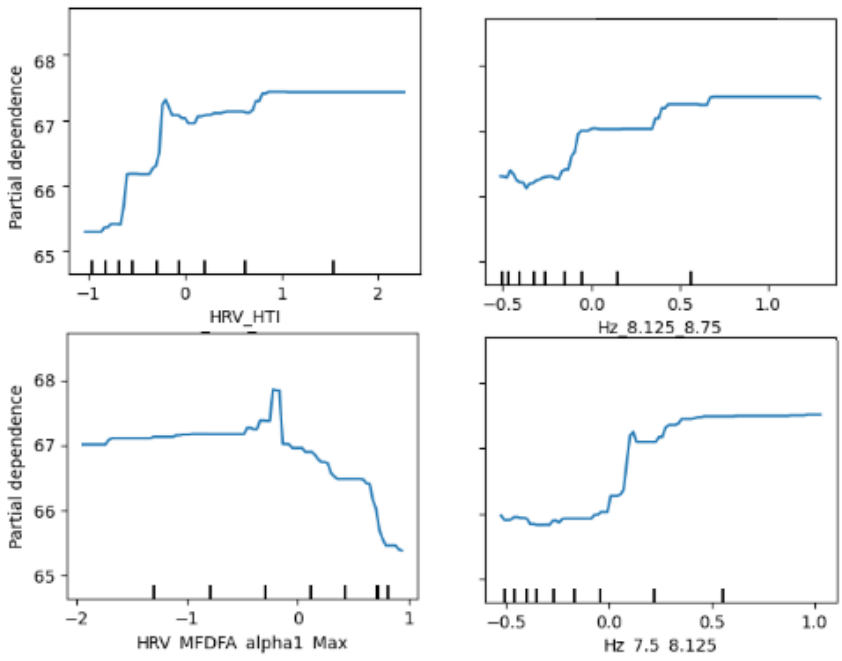

Рисунок 21 – Графики Partial Dependence для признаков с наиболее сильным наклоном на определенном диапазоне значений для модели CatBoost для оценки диастолического АД

Таким образом, в особенности для определенного диапазона значений признаков, существенное влияние на предсказание целевой переменной могут оказывать частотные признаки относительной мощности сигнала ФПГ в диапазоне частот от 8.125 до 8.75 Гц и от 7.5 до 8.125 Гц, а также признаки ВСР треугольного индекса и показателя максимального колебания сигнала по флуктуационному анализу относительно тренда. При сравнении со скатерограммой SHAP отмечается аналогичная прямая либо обратно пропорциональная зависимость для указанных признаков с целевой переменной. Для части графиков, соответствующим определенным признакам, присутствует наиболее ярко выраженная нелинейная зависимость с целевой переменной. Данные графики приведены на рисунке 22.

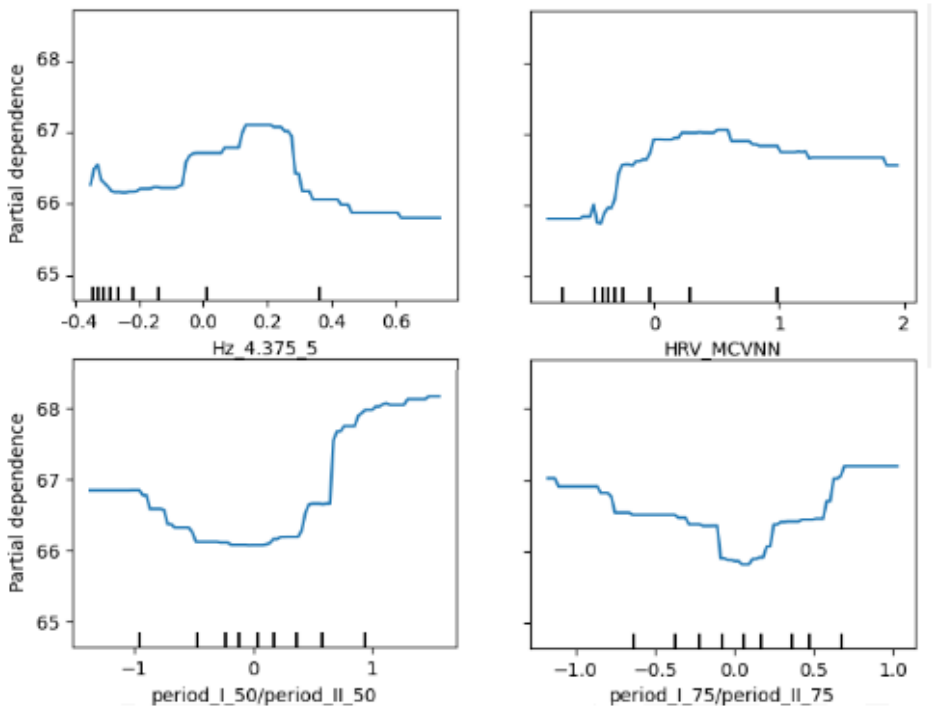

Рисунок 22 – Графики Partial Dependence для признаков с выраженной нелинейной зависимостью с целевой переменной для модели CatBoost для оценки диастолического АД

Исходя из выше приведенных графиков, можно отметить выраженную нелинейную зависимость со значением диастолического АД для морфологических признаков отношений временных интервалов до и после

систолического пика на уровнях амплитуды сигнала ФПГ 50% и 75%, для частотного признака относительной мощности сигнала ФПГ в диапазоне частот от 4.375 Гц до 5 Гц, а также для признака ВСР отношения медианного абсолютного отклонения к медианному значению для временного интервала между соседними систолическими пиками.

В Приложении Г приведены графики локальной интерпретируемости SHAP типа ‘водопад’ для конкретных точек данных. На рисунках Г. и Г.2 представлены графики для примера двух точек, разница между предсказанными и истинными значениями которых составляет не более 1 мм рт. ст. Для данных точек часть значимых признаков совпадает с основными значимыми признаками для глобальной интерпретируемости, отмеченными выше. Для примера Г.1 это величина фрактального измерения Хигучи, временной интервал после систолического пика, а также 20-й процентиль интервалов между соседними систолическими пиками. Для примера Г.2 это признак относительной мощности сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц, временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 25%, а также 20-й процентиль интервалов между соседними систолическими пиками. Однако, определенные менее значимые признаки в смысле глобальной интерпретируемости проявляют значимость для данных точек. Для примера Г.1 это признак относительной мощности сигнала ФПГ в диапазоне частот от 5.625 до 6.25 Гц, отношение медианного абсолютного отклонения к медианному значению для временного интервала между соседними систолическими пиками. Для примера Г.2 это признак относительной мощности сигнала ФПГ в диапазоне частот от 8.125 до 8.25 Гц, а средняя частота сердечных сокращений. На рисунке Г.1 отмечается основной положительный вклад признаков, который приводит к достаточно точному предсказанному значению выше среднего. На рисунке Г.2 отмечается основной отрицательный вклад признаков, который приводит к достаточно точному предсказанному значению ниже среднего. На рисунках Г.3 и Г.4 представлены графики для примера двух точек, предсказанные значения для

которых занижены более чем на 40 мм рт. ст. по сравнению с истинным значением. Аналогично предыдущим точкам, часть значимых признаков совпадает с основными значимыми признаками для глобальной интерпретируемости. Для примера Г.3 это временной интервал после систолического пика, показатель максимального колебания сигнала по флуктуационному анализу относительно тренда. Для примера Г.4 это временной интервал после систолического пика, отношение временных интервалов до и после систолического пика. Аналогично менее значимые признаки в смысле глобальной интерпретируемости проявляют значимость для данных точек. Для примера Г.3 это признаки относительной мощности сигнала ФПГ в диапазоне частот от 7. 5 до 8.125 Гц, вклады ускорения сердечного ритма в долгосрочную и кратковременную ВСР. Для примера В.4 это признак относительной мощности сигнала ФПГ в диапазоне частот от 8.125 до 8.75 Гц, отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 25%. На рисунке Г.3 отмечается основной положительный вклад признаков, который оказался недостаточным и привел к ошибочному заниженному значению. На рисунке Г.4 можно отметить взаимную компенсацию положительных и отрицательных вкладов признаков, как следствие, ошибочное заниженное значение в районе среднего значения целевой переменной. На рисунках Г.5 и Г.6 представлены графики для примера двух точек, предсказанные значения для которых завышены более чем на 20 мм рт. ст. по сравнению с истинным значением. Аналогично предыдущим точкам, часть значимых признаков совпадает с основными значимыми признаками для глобальной интерпретируемости. Для примера Г.5 это величина фрактального измерения Хигучи, временной интервал после систолического пика, 20-й процентиль интервалов между соседними систолическими пиками. Для примера Г.6 это 20-й процентиль интервалов между соседними систолическими пиками, относительная мощность сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц. Аналогично менее значимые признаки в смысле глобальной интерпретируемости проявляют значимость

для данных точек. Для примера Г.5 это вклад ускорения сердечного ритма в кратковременную ВСР, процент коротких сегментов ВСР. Для примера Г.6 это временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 33%, отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 50%. На обоих графиках отмечается основной положительный вклад признаков, который приводит к ошибочному завышенному значению.

Таким образом, значимыми признаками для предсказания диастолического АД являются признаки всех рассмотренных групп признаков, без явного выделения преимущественно значимой группы признаков. Итоговый результат предсказания модели формируется сложным образом с учетом множества признаков как суммарный вклад всех признаков, при этом каждый признак вносит свой относительно небольшой вклад в итоговый результат предсказания модели.

3.4 Обсуждение полученных результатов.

В данном подразделе приводится обсуждение результатов, полученных с использованием модели CatBoost для предсказания систолического и диастолического АД, для которого получились лучшие метрики в сравнении с результатами других рассматриваемых моделей машинного обучения.

Ниже в таблице 3 приведена сравнительная таблица производительности модели машинного обучения CatBoost в зависимости от выбора опций, а именно использование разных групп признаков, проведение отбора признаков, отчистки от аномалий на границах диапазонов систолического и диастолического АД:

Таблица 3 – Производительность модели CatBoost в зависимости от выбора опций, MAE ± STD мм. рт. ст./ R2

Опции	**Выбор / результат**						
морфологические	✓			✓	✓	✓	✓

Продолжение таблицы 3

ВСР		✓		✓	✓	✓	✓
частотные			✓	✓	✓	✓	✓
отбор признаков					✓		✓
без аномалий на границах диапазона						✓	✓
MAE ± STD мм. рт. ст. / R2, **систолическое АД**	13.5 ± 10.9/ 0.47	17.2 ± 13.5/ 0.13	14.6 ± 12.2/ 0.35	13.2 ± 11.7/ 0.44	12.5 ± 11.3/ 0.48	13.1 ± 11.4/ 0.46	**12.3 ± 11.1/ 0.51**
MAE ± STD мм. рт. ст. / R2, **диастолическое АД**	8.1 ± 8.1/ 0.15	7.8 ± 7.3/ 0.16	7.7 ± 7.6/ 0.14	7.0 ± 7.1/ 0.26	6.8 ± 6.9/ 0.31	7.2 ± 8.0/ 0.27	**6.9 ± 7.6/ 0.33**

Исходя из данной таблицы можно сделать следующие выводы:

1) по результатам использования каждой из группы признаков по отдельности наилучший результат достигается с использованием морфологической группы признаков для предсказания систолического АД;

2) по результатам использования каждой из группы признаков по отдельности для предсказания диастолического АД преимущественная группа признаков по влиянию на результат явно не выделяется, но при использовании всех групп признаков одновременно итоговый результат существенно улучшается;

3) процедура отбора используемых признаков для модели приводит к улучшению результата как для предсказания систолического, так и для предсказания диастолического АД;

4) процедура отчистки от аномалий на границах диапазонов систолического и диастолического АД приводит к улучшению результата как для предсказания систолического, так и для предсказания диастолического АД;

5) наилучший результат результата как для предсказания систолического, так и для предсказания диастолического АД, достигается с применением всех опций, таких как использование всех групп признаков, проведение процедуры отбора признаков, проведение процедуры отчистки от аномалий на границах диапазонов систолического и диастолического АД.

Из представленных выше результатов следует, что механизм предсказания систолического АД отличается от предсказания диастолического АД. Для предсказания систолического АД наиболее существенный вклад вносят морфологические признаки, в то время как для предсказания диастолического АД вклад вносит совокупность всех групп признаков. Тем не менее, наилучший результат получается с использованием всех групп признаков как для предсказания систолического, так и для предсказания диастолического АД. Также согласно метрике R2 значения систолического АД предсказываются точнее с результатом 0.51, чем значения диастолического АД с результатом 0.33. Полученные данные согласуется с результатами интерпретацией работы модели, приведенной в предыдущей главе: в число наиболее значимых признаков модели для предсказания систолического АД входят признаки из морфологичеческой и частотной группы, в то время как для предсказания систолического АД в число наиболее значимых признаков модели входят признаки всех групп.

Поскольку процедура отбора признаков улучшила результат как для предсказания систолического, так и для предсказания диастолического АД, полученные модели остаются чувствительными к выбору используемых признаков. Модель для предсказания систолического АД включает 62 признака, модель для предсказания диастолического АД включает 48 признаков. Ввиду множества используемых признаков модели являются сложными, итоговая производительность которых является результатом совокупности вкладов каждого из признаков. Результаты интерпретации работы моделей, приведенной в предыдущей главе, также указывают на сложность модели и нелинейную зависимость признаков и целевой переменной.

Поскольку процедура отчистки от аномалий на границах диапазонов улучшила результат как для предсказания систолического, так и для предсказания диастолического АД, полученные модели остаются чувствительными к выбору используемых данных и наличия в них аномалий.

Таким образом, из трех рассмотренных моделей машинного обучения лучший результат был получен с помощью модели CatBoost с применением всех указанных выше опций. Получены значения метрик MAE ± STD равной 12.3 ± 11.1 мм. рт. ст. и R2 равному 0.51 для предсказания систолического АД, а также MAE ± STD равной 6.9 ± 7.6 мм. рт. ст. и R2 равным 0.33 для предсказания диастолического АД. Распределение ошибок и абсолютных ошибок в смысле разницы между истинным и предсказанным значением для данных тестовой выборки, которая составляет 20% от первоначальной выборки, а именно 453 точки, представлены в приложениях Д и Е для предсказания систолического и диастолического давления соответственно.

Данный результат требует дальнейшего улучшения для соответствия стандарту AAMI, который определяет среднюю ошибку не более 5 мм рт. ст. и стандартное отклонение не более 8 мм рт. ст. для оценки систолического и диастолического АД с размером выборки не менее 85 субъектов.

Для улучшения полученного результата рекомендуется собрать собственный набор данных с использованием идентичных медицинских приборов и датчиков для регистрации ФПГ и сигнала инвазивного АД с выборкой рекомендуемого размера на 1000 пациентов отделений интенсивной терапии. Сигналы ФПГ и инвазивного АД рекомендуется регистрировать с большей частотой дискретизации от 250 Гц для получения более точных характеристик соответствующих сигналов. Сигналы ФПГ и инвазивного АД для каждого пациента рекомендуется проверить вручную на предмет аномалий и выбрать для обучения модели только сигналы без аномалий. Рекомендуется рассмотреть дополнительный морфологический признак наличия либо отсутствие диастолического пика сигнала ФПГ, а также амплитудные характеристики сигнала ФПГ. Помимо признаков непосредственно сигнала ФПГ, рекомендуется учесть дополнительно физиологические признаки пациентов, такие как пол, возраст, вес, рост, индекс массы тела.

3.5 Сравнение полученных результатов с результатами аналогичных исследований.

Результаты текущего исследования, проведенного по предсказанию систолического и диастолического артериального давления по признакам сигнала ФПГ, были сопоставлены с результатами других исследований по данной теме, проведенных с использованием аналогичного набора данных UCI. Сравнение результатов исследований по метрике MAE представлено в таблице 4.

Таблица 4 – Сравнение результатов исследований по предсказанию систолического и диастолического АД по признакам сигнала ФПГ, проведенных на наборе данных UCI, MAE мм. рт. ст.

Статья	**Год**	**Модель**	**MAE SBP, мм. рт. ст.**	**MAE DBP, мм. рт. ст.**
[26]	2023	LightGBM	16.9	8.2
		SVR	17.5	8.1
		RF	16.9	8.3
		MLP	18.2	8.2
		AdaBoost	16.9	8.7
		ResNet	16.6	8.3
		SpectroResNet	19.9	9.0
		MLPBP	17.6	8.4
		U-Net	16.9	7.9
		PPGIABP	17.1	8.1
		V-Net	17.6	9.0
[36]	2023	SVR	16.7	-
текущее исследование	2024	LR	16.1	8.0
	2024	SVR	12.7	7.0
	2024	**CatBoost**	**12.3**	**6.9**
[31]	2020	LRCN	4.0	2.3
[15]	2023	SE-MSResUNet	3.9*	2.2*
			21.3**	12.7**
[8]	2022	MLP	2.7	1.0

Продолжение таблицы 4

* результат для набора данных UCI
** результат для проверочного набора данных

Приводится сравнение производительности нескольких моделей машинного обучения для нескольких наборов данных, в том числе для набора данных UCI в работе [26]. Для моделей LightGBM, SVR, RF, MLP, AdaBoost используется стратегия предсказания АД, при которой из сигнала ФПГ извлекаются морфологические признаки с использованием первой и второй производных для отдельных фаз сигнала ФПГ [4], [6], [22]. Для моделей ResNet, SpectroResNet, MLPBP на входе принимается непрерывный сигнал ФПГ в виде исходного временного ряда, на выходе предсказываются дискретные значения систолического и диастолического АД [9], [30], [33]. Для моделей U-Net, PPGIABP, V-Net на входе принимается непрерывный сигнал ФПГ в виде исходного временного ряда, на выходе предсказываются непрерывный сигнал инвазивного АД [10], [12], [27].

Использовался ряд морфологических признаков с использованием первой и второй производных, извлеченных из отдельных фаз сигналов ФПГ в работе [36]. При этом для предсказания систолического АД был применен метод опорных векторов с радиальным ядром.

Использовалась многослойная нейронная сеть со сверточными блоками, а также блоками долгой краткосрочной памяти LSTM в работе [31]. На вход сети подавался сегмент исходного сигнала ФПГ, на выходе предсказывались дискретные значения систолического и диастолического АД, а также частоты сердечных сокращений.

Применялась специально модернизированная нейронная сеть SE-MSResUNet на основе сети U-net, которая включает дополнительные модули в блоки кодирования для извлечения многомасштабной информации и более сложным обучением весов, в работе [15]. На входе нейронной сети принимается сегмент непрерывного сигнала ФПГ в виде исходного

временного ряда, на выходе предсказывается сегмент непрерывного сигнала инвазивного АД.

Использовалась многослойная нейронная сеть с блоком U-Net для извлечения признаков из входного сигнала, а также с несколькими сверточными слоями для предсказания сегмента сигнала инвазивного АД, в работе [8]. В качестве входного сигнала принимался трехканальный сигнал: сегмент исходного сигнала ФПГ, первая производная сегмента сигнала ФПГ и вторая производная сигнала ФПГ.

Таким образом, результат текущего исследования, полученный с помощью модели CatBoost с использованием отобранных признаков сигнала ФПГ из морфологической группы, частотной группы и группы ВСР превосходит значительную часть результатов, полученных с помощью других моделей, в том числе с применением нейронных сетей. Однако, полученный результат остается ниже другой части результатов, полученных с применение специальных нейронных сетей с применением сверточных блоков, блоков LSTM, а также с использованием блоков автокодировщиков для извлечения признаков.

Впрочем, следует отметить вероятную низкую обобщающую способность применения специальных нейронных сетей для сторонних наборов данных. В частотности, отмечается существенное ухудшение производительности модели SE-MSResUNet для стороннего набора данных со значений MAE 3.9 мм. рт. ст. для систолического АД и 2.2 мм. рт. ст. для диастолического АД до значений MAE 21.3 мм. рт. ст. для систолического АД и 12.7 мм. рт. ст. для диастолического АД в работе [15]. Отмечается, что предварительная калибровка нейронной сети SE-MSResUNet для нового набора данных улучшает значения MAE до 9.3 мм. рт. ст. для систолического АД и 4.5 мм. рт. ст. для диастолического АД. Отсутствует информация о результатах для проверочного набора данных с использованием признаков сигнала ФПГ в работах [6], [31].

Для текущего исследования полученная модель является универсальной и не требует дополнительной настройки или калибровки, поскольку используемые морфологические признаки принадлежат временной области, как и признаки группы BCP, а для признаков частотной группы используются относительные значения мощностей для определенных диапазонов частот. Также результат предсказания разработанной модели может быть интерпретирован с помощью методов интерпретации как в целом, так и для конкретных предсказанных значений с указанием степени влияния наиболее значимых признаков.

Тем не менее, наиболее высокие результаты метрики MAE были получены при обучении специальных нейронных сетей для конкретного набора данных. Данный результат может быть использован при обучении аналогичных нейронных сетей на собственном наборе данных, собранного с использованием идентичных медицинских приборов и датчиков для регистрации ФПГ и сигнала инвазивного АД, и дальнейшего предсказания значений АД на основе сигнала ФПГ, зарегистрированного с помощью идентичного медицинского оборудования.

ЗАКЛЮЧЕНИЕ

В настоящем исследовании в соответствии с целью разработан прототип алгоритма машинного обучения, позволяющий предсказать систолическое и диастолическое АД с использованием признаков сигнала ФПГ. Для достижения поставленной цели были решены поставленные задачи.

Выполнен обзор источников литературы. Рассмотренные исследования подтверждают актуальность проблемы проведения непрерывного измерения АД, а также указывают на перспективу развития направления оценки АД с помощью характеристик сигнала ФПГ методами машинного обучения. В то же время отмечается сложный характер взаимосвязи между значениями АД и признаками сигнала ФПГ, а также необходимость проведения дополнительных исследований в данной области.

Выбран набор данных, методы и метрики для оценки результатов. Для настоящего исследования было использовано 2265 записей набора данных UCI, который включает синхронизированные записи сигналов ФПГ и инвазивного АД пациентов отделений интенсивной терапии. В качестве признаков сигнала ФПГ рассмотрены временные морфологические признаки, признаки вариабельности сердечного ритма ВСР, частотные признаки как относительные мощности сигнала в заданном диапазоне частот. В качестве моделей машинного обучения использованы линейная регрессия, метод опорных векторов, модель градиентного бустинга на основе деревьев решений CatBoost. В качестве метрик выбраны средняя абсолютная ошибка, стандартное отклонение абсолютной ошибки, коэффициент детерминации. Метрики оценивались на тестовой части набора данных, которая составила 20% от первоначальной выборки.

Выполнено сравнение методов машинного обучения, полученный результат был интерпретирован. Из трех рассмотренных моделей лучший результат получен с помощью модели CatBoost с использованием признаков всех групп, отбором признаков и частичной отчистки от аномалий.

Полученные значения метрик MAE ± STD / R2 составляют 12.3 ± 11.1 мм. рт. ст. / 0.51 для предсказания систолического АД и 6.9 ± 7.6 мм. рт. ст. / 0.33 для предсказания диастолического АД. По результатам выполненной интерпретации, наиболее значимыми признаками для предсказания систолического АД являются признаки морфологической и частотной групп, в то время как для предсказания диастолического АД преимущественно значимая группа признаков не выделяется. Полученные модели являются сложными, итоговый результат которых формируется как суммарный вклад всех признаков, где каждый признак вносит свой относительно небольшой вклад в итоговый результат предсказания модели. По метрике MAE данный результат превосходит многие модели машинного обучения на основе аналогичного набора данных.

Практическая значимость данной работы заключается в использовании полученных результатов для разработки более эффективного алгоритма с целью соответствия стандартам медицинского оборудования. Рекомендуется собрать собственный набор данных с использованием идентичных медицинских приборов и датчиков для регистрации ФПГ и сигнала инвазивного АД с повышенной частотой дискретизации сигналов. Для полученного набора рекомендуется рассмотреть дополнительные морфологические и амплитудные характеристики сигнала ФПГ, учесть физиологические признаки пациентов, а также исследовать применение LSTM и сверточных нейронных сетей с автокодировщиками для извлечения признаков сигнала ФПГ.

Основные результаты настоящего исследования в формате тезисов приняты к публикации в сборнике всероссийской научной студенческой конференции «ИНТЕР – Информационные технологии и радиоэлектроника», а также представлены на постерной секции в рамках международной конференции 2024 USBEREIT.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Биомедицинские сигналы и изображения в цифровом здравоохранении: хранение, обработка и анализ : учебное пособие / В. С. Кубланов, А. Ю. Долганов, В. Б. Костоусов [и др.] ; под общей редакцией В. С. Кубланова ; Министерство науки и высшего образования Российской Федерации, Уральский федеральный университет имени первого Президента России Б.Н. Ельцина. – Екатеринбург : Издательство Уральского университета, 2020. – 240 с. – ISBN 978-5-7996-2990-8. – EDN HAIFIM.

2. Долганов, А. Ю. Применение нейронных сетей в задаче косвенной оценки артериального давления по данным вариабельности сердечного ритма / А. Ю. Долганов // IEEE XXII Международная конференция молодых специалистов в области электронных приборов и материалов (EDM 2021). – Новосибирск: Новосибирский государственный технический университет, 2021. – С. 428-434. – EDN QJZNNA.

3. Лебедев Г.С., Шадеркин И.А., Порубаева Э. Э., Шадеркина А.И. Технологии продолжительного мониторинга артериального давления: перспективы практического применения // Журнал телемедицины и электронного здравоохранения. 2020. №1. URL: https://cyberleninka.ru/article/n/tehnologii-prodolzhitelnogo-monitoringa-arterialnogo-davleniya-perspektivy-prakticheskogo-primeneniya (дата обращения: 20.03.2024).

4. A Benchmark Study of Machine Learning for Analysis of Signal Feature Extraction Techniques for Blood Pressure Estimation Using Photoplethysmography (PPG) / S. Maqsood, S. Xu, M. Springer, R. Mohawesh // IEEE Access. – 2021. – Vol. 9. – P. 138817-138833.

5. A Comparison of Deep Learning Techniques for Arterial Blood Pressure Prediction / A. Paviglianiti, V. Randazzo, S. Villata [et al.] // Cognitive Computation. – 2022. – Vol. 14. – № 5. – P. 1689-1710.

6. A feature exploration methodology for learning based cuffless blood pressure measurement using photoplethysmography / K. Duan, Z. Qian, M. Atef, G. Wang. – Text : electronic // 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). – Orlando, FL, USA : IEEE, 2016. – P. 6385-6388. – URL: http://ieeexplore.ieee.org/document/7592189/ (date accessed: 20.03.2024).

7. A Novel Neural Network Model for Blood Pressure Estimation Using Photoplethesmography without Electrocardiogram / L. Wang, W. Zhou, Y. Xing, X. Zhou // Journal of Healthcare Engineering. – 2018. – Vol. 2018. – P. 1-9.

8. A Shallow U-Net Architecture for Reliably Predicting Blood Pressure (BP) from Photoplethysmogram (PPG) and Electrocardiogram (ECG) Signals / S. Mahmud, N. Ibtehaz, A. Khandakar [et al.] // Sensors. – 2022. – Vol. 22. – № 3. – P. 919.

9. Assessment of Non-Invasive Blood Pressure Prediction from PPG and rPPG Signals Using Deep Learning / F. Schrumpf, P. Frenzel, C. Aust [et al.] // Sensors. – 2021. – Vol. 21. – № 18. – P. 6022.

10. Athaya, T. An Estimation Method of Continuous Non-Invasive Arterial Blood Pressure Waveform Using Photoplethysmography: A U-Net Architecture-Based Approach / T. Athaya, S. Choi // Sensors. – 2021. – Vol. 21. – An Estimation Method of Continuous Non-Invasive Arterial Blood Pressure Waveform Using Photoplethysmography. – № 5. – P. 1867.

11. Blood Pressure Estimation Using Photoplethysmography Only: Comparison between Different Machine Learning Approaches / S. G. Khalid, J. Zhang, F. Chen, D. Zheng // Journal of Healthcare Engineering. – 2018. – Vol. 2018. – Blood Pressure Estimation Using Photoplethysmography Only. – P. 1-13.

12. Blood Pressure Morphology Assessment from Photoplethysmogram and Demographic Information Using Deep Learning with Attention Mechanism / N. Aguirre, E. Grall-Maës, L. J. Cymberknop, R. L. Armentano // Sensors. – 2021. – Vol. 21. – № 6. – P. 2167.

13. Building Continuous Arterial Blood Pressure Prediction Models Using Recurrent Networks / C. Sideris, H. Kalantarian, E. Nemati, M. Sarrafzadeh. – Text : electronic // 2016 IEEE International Conference on Smart Computing (SMARTCOMP). – St Louis, MO, USA : IEEE, 2016. – P. 1-5. – URL: http://ieeexplore.ieee.org/document/7501681/ (date accessed: 20.03.2024).

14. Can Photoplethysmography Replace Arterial Blood Pressure in the Assessment of Blood Pressure? / G. Martínez, N. Howard, D. Abbott [et al.] // Journal of Clinical Medicine. – 2018. – Vol. 7. – № 10. – P. 316.

15. Continuous non-invasive arterial blood pressure monitoring with photoplethysmography via SE-MSResUNet network / K. Ma, L. Zou, F. Yang [et al.] // Biomedical Signal Processing and Control. – 2024. – Vol. 90. – P. 105862.

16. Cuffless Blood Pressure Estimation Based on Photoplethysmography Signal and Its Second Derivative / M. Liu, L.-M. Po, H. Fu // International Journal of Computer Theory and Engineering. – 2017. – Vol. 9. – № 3. – P. 202-206.

17. Cuff-less PPG based continuous blood pressure monitoring — A smartphone based approach / A. Gaurav, M. Maheedhar, V. N. Tiwari, R. Narayanan. – Text : electronic // 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). – Orlando, FL, USA : IEEE, 2016. – P. 607-610. – URL: http://ieeexplore.ieee.org/document/7590775/ (date accessed: 20.03.2024).

18. Cuff-less high-accuracy calibration-free blood pressure estimation using pulse transit time / M. Kachuee, M. M. Kiani, H. Mohammadzade, M. Shabany. – Text : electronic // 2015 IEEE International Symposium on Circuits and Systems (ISCAS). – Lisbon, Portugal : IEEE, 2015. – P. 1006-1009. – URL: http://ieeexplore.ieee.org/document/7168806/ (date accessed: 03.05.2024).

19. Data-driven estimation of blood pressure using photoplethysmographic signals / S. C. Gao, P. Wittek, L. Zhao, W. J. Jiang. – Text : electronic // 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). – Orlando, FL, USA : IEEE, 2016. – P. 766-769. – URL: http://ieeexplore.ieee.org/document/7590814/ (date accessed: 20.03.2024).

20. Dolganov, A. Application of the Evolutionary Programming for Indirect Evaluation of Blood Pressure based on Heart Rate Variability Parameters / A. Dolganov. – Text : electronic // 2020 Ural Symposium on Biomedical Engineering, Radioelectronics and Information Technology (USBEREIT). – Yekaterinburg, Russia : IEEE, 2020. – P. 0139-0142. – URL: https://ieeexplore.ieee.org/document/9117788/ (date accessed: 11.05.2024).

21. Dey, J. InstaBP: Cuff-less Blood Pressure Monitoring on Smartphone using Single PPG Sensor / J. Dey, A. Gaurav, V. N. Tiwari. – Text : electronic // 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). – Honolulu, HI : IEEE, 2018. – InstaBP. – P. 5002-5005. – URL: https://ieeexplore.ieee.org/document/8513189/ (date accessed: 20.03.2024).

22. El-Hajj, C. A review of machine learning techniques in photoplethysmography for the non-invasive cuff-less measurement of blood pressure / C. El-Hajj, P. A. Kyriacou // Biomedical Signal Processing and Control. – 2020. – Vol. 58. – P. 101870.

23. Estimating blood pressure using Windkessel model on photoplethysmogram / A. D. Choudhury, R. Banerjee, A. Sinha, S. Kundu. – Text : electronic // 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). – Chicago, IL : IEEE, 2014. – P. 4567-4570. – URL: http://ieeexplore.ieee.org/document/6944640/ (date accessed: 20.03.2024).

24. Features Extraction for Cuffless Blood Pressure Estimation by Autoencoder from Photoplethysmography / S. Shimazaki, S. Bhuiyan, H. Kawanaka, K. Oguri. – Text : electronic // 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). – Honolulu, HI : IEEE, 2018. – P. 2857-2860. – URL: https://ieeexplore.ieee.org/document/8512829/ (date accessed: 20.03.2024).

25. Fujita, D. PPG-Based Systolic Blood Pressure Estimation Method Using PLS and Level-Crossing Feature / D. Fujita, A. Suzuki, K. Ryu // Applied Sciences. – 2019. – Vol. 9. – № 2. – P. 304.

26. Gonzalez, S. A benchmark for machine-learning based non-invasive blood pressure estimation using photoplethysmogram / S. Gonzalez, W.-T. Hsieh, T. P.-C. Chen // Scientific Data. – 2023. – Vol. 10. – № 1. – P. 149.

27. Imputation of the continuous arterial line blood pressure waveform from non-invasive measurements using deep learning / B. L. Hill, N. Rakocz, Á. Rudas [et al.] // Scientific Reports. – 2021. – Vol. 11. – № 1. – P. 15755.

28. Innovative continuous non-invasive cuffless blood pressure monitoring based on photoplethysmography technology / J. C. Ruiz-Rodríguez, A. Ruiz-Sanmartín, V. Ribas [et al.] // Intensive Care Medicine. – 2013. – Vol. 39. – № 9. – P. 1618-1625.

29. Kurylyak, Y. A Neural Network-based method for continuous blood pressure estimation from a PPG signal / Y. Kurylyak, F. Lamonaca, D. Grimaldi. – Text : electronic // 2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). – Minneapolis, MN, USA : IEEE, 2013. – P. 280-283. – URL: http://ieeexplore.ieee.org/document/6555424/ (date accessed: 20.03.2024).

30. MLP-BP: A novel framework for cuffless blood pressure measurement with PPG and ECG signals based on MLP-Mixer neural networks / B. Huang, W. Chen, C.-L. Lin [et al.] // Biomedical Signal Processing and Control. – 2022. – Vol. 73. – MLP-BP. – P. 103404.

31. PP-Net: A Deep Learning Framework for PPG-Based Blood Pressure and Heart Rate Estimation / M. Panwar, A. Gautam, D. Biswas, A. Acharyya // IEEE Sensors Journal. – 2020. – Vol. 20. – PP-Net. – № 17. – P. 10000-10011.

32. Senturk, U. Towards wearable blood pressure measurement systems from biosignals: a review / U. Senturk, K. Polat, İ. Yucedag // Turkish journal of electrical engineering & computer sciences. – 2019. – Vol. 27. – Towards wearable blood pressure measurement systems from biosignals. – № 5. – P. 3259-3281.

33. Slapnicar, G. Blood Pressure Estimation from Photoplethysmogram Using a Spectro-Temporal Deep Neural Network / G. Slapnicar, N. Mlakar, M. Luštrek // Sensors. – 2019. – Vol. 19. – № 15. – P. 3420.

34. Teng, X. F. Continuous and noninvasive estimation of arterial blood pressure using a photoplethysmographic approach / X. F. Teng, Y. T. Zhang. – Text : electronic // 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. – Cancun, Mexico : IEEE, 2003. – P. 3153-3156. – URL: http://ieeexplore.ieee.org/document/1280811/ (date accessed: 20.03.2024).

35. Toward Ubiquitous Blood Pressure Monitoring via Pulse Transit Time: Theory and Practice / R. Mukkamala, J.-O. Hahn, O. T. Inan [et al.] // IEEE Transactions on Biomedical Engineering. – 2015. – Vol. 62. – Toward Ubiquitous Blood Pressure Monitoring via Pulse Transit Time. – № 8. – P. 1879-1901.

36. Weber-Boisvert, G. Intensive care photoplethysmogram datasets and machine-learning for blood pressure estimation: Generalization not guarantied / G. Weber-Boisvert, B. Gosselin, F. Sandberg // Frontiers in Physiology. – 2023. – Vol. 14. – Intensive care photoplethysmogram datasets and machine-learning for blood pressure estimation. – P. 1126957.

37. Xing, X. Optical blood pressure estimation with photoplethysmography and FFT-based neural networks / X. Xing, M. Sun // Biomedical Optics Express. – 2016. – Vol. 7. – № 8. – P. 3007.

38. − Гипертония : офиц. сайт. – URL: https://www.who.int/ru/news-room/fact-sheets/detail/hypertension (дата обращения: 20.03.24).

39. – The MIMIC Database : офиц. сайт. – URL: https://archive.physionet.org/physiobank/database/mimicdb/ (дата обращения: 20.03.24).

40. – The MIMIC II Waveform Database : офиц. сайт. – URL: https://archive.physionet.org/physiobank/database/mimic2wdb/ (дата обращения: 20.03.24).

41. – MIMIC-III Waveform Database v1.0 : офиц. сайт .– URL: https://physionet.org/content/mimic3wdb/1.0/ (дата обращения: 20.03.24).

42. – MIMIC-IV Waveform Database v0.1.0 : офиц. сайт. – URL: https://physionet.org/content/mimic4wdb/0.1.0/ (дата обращения: 20.03.24).

43. – Cuff-Less Blood Pressure Estimation – UCI Machine Learning Repository : офиц. сайт. – URL: https://archive.ics.uci.edu/dataset/340/cuff+less+blood+pressure+estimation (дата обращения: 20.03.24).

44. – PPG – NeuroKit2 0.2.8 documentation: [офиц. сайт]. URL: https://neuropsychology.github.io/NeuroKit/functions/ppg.html#ppg-intervalrelated (дата обращения: 26.03.24).

45. – The University of Queensland Vital Signs Dataset : офиц. сайт. – URL: https://outbox.eait.uq.edu.au/uqdliu3/uqvitalsignsdataset/index.html (дата обращения: 20.03.24).

ПРИЛОЖЕНИЕ А

Используемые признаки сигнала ФПГ с расшифровкой модели CatBoost для предсказания систолического АД

Таблица А.1 – Список признаков с расшифровкой модели CatBoost для предсказания систолического АД

Обозначение признака	Расшифровка
Группа морфологических признаков	
period_I	временной интервал до систолического пика
period_II	временной интервал после систолического пика
period_I/period_II	отношение временных интервалов до и после систолического пика
period_I_25	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 25%
period_II_25	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 25%
period_I_25/period_II_25	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 25%
period_I_33	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 33%
period_II_33	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 33%
period_I_33/period_II_33	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 33%
period_I_50	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 50%
period_II_50	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 50%
period_I_50/period_II_50	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 50%
period_I_66	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 66%
period_II_66	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 66%

Продолжение ПРИЛОЖЕНИЯ А

Продолжение таблицы А.1

Обозначение признака	Расшифровка
period_I_66/period_II_66	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 66%
period_I_75	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 75%
period_II_75	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 75%
period_I_75/period_II_75	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 75%
Группа признаков вариабельности сердечного ритма	
PPG_Rate_Mean	средняя частота сердечных сокращений
Подгруппа временных показателей ВСР	
HRV_MedianNN	медианное значение RR интервала
HRV_MadNN	медианное абсолютное отклонение значений RR интервалов
HRV_MCVNN	отношение медианного абсолютного отклонения значений RR интервалов к медианному значению интервала RR
HRV_IQRNN	межквартильный размах значений интервалов RR
HRV_Prc80NN	80-й процентиль интервалов RR
HRV_pNN50	доля интервалов RR длительностью более 50 мс от общего количества интервалов RR
HRV_pNN20	доля интервалов RR длительностью более 20 мс от общего количества интервалов RR
HRV_MinNN	минимальное значение RR интервала
HRV_MaxNN	максимальное значение RR интервала
HRV_TINN	треугольная интерполяция гистограммы RR интервалов
HRV_HTI	треугольный индекс ВСР

Продолжение ПРИЛОЖЕНИЯ А

Продолжение таблицы А.1

Обозначение признака	Расшифровка
Подгруппа нелинейных показателей ВСР	
HRV_SD1SD2	отношение стандартного отклонения перпендикулярно линии идентичности к стандартному отклонению вдоль лини идентичности для графика Пуанкаре
HRV_PI	отношение количества точек ниже линии идентичности к количеству всех точек графика Пуанкаре за исключением точек, лежащих на линии идентичности
HRV_C1a	вклад ускорения сердечного ритма в кратковременную ВСР
HRV_SD2a	долговременная дисперсия вкладов укорочения RR интервалов
HRV_IALS	обратная средняя длина сегментов ускорения/замедления
HRV_PSS	процент коротких сегментов
HRV_ApEn	приблизительная энтропия
HRV_ShanEn	энтропия Шеннона
HRV_MSEn	мультимасштабная энтропия
HRV_CD	корреляционная размерность
HRV_HFD	фрактальная размерность Хигучи
HRV_MFDFA_alpha1_Max	показатель максимального колебания сигнала по мультифрактальному флуктуационному анализу относительно тренда
HRV_MFDFA_alpha1_Delta	диапазон колебаний сигнала по флуктуационному мультифрактальному анализу относительно тренда
HRV_MFDFA_alpha1_Fluctuation	индекс колебаний показателя Херста по мультифрактальному флуктуационному анализу относительно тренда
HRV_MFDFA_alpha1_Increment	кумулятивная функция квадратов приращений обобщенных показателей Херста
Группа частотных признаков	
Hz_0.625_1.25	относительная мощность сигнала ФПГ в диапазоне частот от 0.625 до 1.25 Гц

Продолжение ПРИЛОЖЕНИЯ А

Продолжение таблицы А.1

Обозначение признака	Расшифровка
Hz_1.25_1.875	относительная мощность сигнала ФПГ в диапазоне частот от 1.25 до 1.875 Гц
Hz_1.875_2.5	относительная мощность сигнала ФПГ в диапазоне частот от 1.875 до 2.5 Гц
Hz_3.125_3.75	относительная мощность сигнала ФПГ в диапазоне частот от 3.125 до 3.75 Гц
Hz_4.375_5	относительная мощность сигнала ФПГ в диапазоне частот от 4.375 до 5 Гц
Hz_5_5.625	относительная мощность сигнала ФПГ в диапазоне частот от 5 до 5.625 Гц
Hz_5.625_6.25	относительная мощность сигнала ФПГ в диапазоне частот от 5.625 до 6.25 Гц
Hz_6.25_6.875	относительная мощность сигнала ФПГ в диапазоне частот от 6.25 до 6.875 Гц
Hz_6.875_7.5	относительная мощность сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц
Hz_7.5_8.125	относительная мощность сигнала ФПГ в диапазоне частот от 7.5 до 8.125 Гц
Hz_8.125_8.75	относительная мощность сигнала ФПГ в диапазоне частот от 8.125 до 8.75 Гц
Hz_8.75_9.375	относительная мощность сигнала ФПГ в диапазоне частот от 8.75 до 9.375 Гц
Hz_10_10.625	относительная мощность сигнала ФПГ в диапазоне частот от 10 до 10.625 Гц
Hz_11.875_12.5	относительная мощность сигнала ФПГ в диапазоне частот от 11.875 до 12.5 Гц
Hz_0.0375_0.5	относительная мощность сигнала ФПГ в диапазоне частот от 0.0375 до 0.5 Гц
Hz_0.5_1.875	относительная мощность сигнала ФПГ в диапазоне частот от 0.5 до 1.875 Гц
Hz_1.875_5	относительная мощность сигнала ФПГ в диапазоне частот от 1.875 до 5 Гц

ПРИЛОЖЕНИЕ Б

Используемые признаки сигнала ФПГ с расшифровкой модели CatBoost для предсказания диастолического АД

Таблица Б.1 – Список признаков с расшифровкой модели CatBoost для предсказания диастолического АД

Обозначение признака	Расшифровка
Группа морфологических признаков	
period_I	временной интервал до систолического пика
period_II	временной интервал после систолического пика
period_I/period_II	отношение временных интервалов до и после систолического пика
period_I_25	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 25%
period_II_25	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 25%
period_I_25/period_II_25	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 25%
period_I_33	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 33%
period_II_33	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 33%
period_I_33/period_II_33	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 33%
period_I_50	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 50%
period_II_50	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 50%
period_I_50/period_II_50	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 50%
period_I_66	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 66%
period_II_66	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 66%

Продолжение ПРИЛОЖЕНИЯ Б

Продолжение таблицы Б.1

Обозначение признака	Расшифровка
period_I_66/period_II_66	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 66%
period_I_75	временной интервал до систолического пика на уровне амплитуды сигнала ФПГ 75%
period_II_75	временной интервал после систолического пика на уровне амплитуды сигнала ФПГ 75%
period_I_75/period_II_75	отношение временных интервалов до и после систолического пика на уровне амплитуды сигнала ФПГ 75%
Группа признаков вариабельности сердечного ритма	
PPG_Rate_Mean	средняя частота сердечных сокращений
Подгруппа временных показателей ВСР	
HRV_MCVNN	отношение медианного абсолютного отклонения значений RR интервалов к медианному значению интервала RR
HRV_IQRNN	межквартильный размах значений интервалов RR
HRV_Prc20NN	20-й процентиль интервалов RR
HRV_MaxNN	максимальное значение RR интервала
HRV_HTI	треугольный индекс ВСР
Подгруппа нелинейных показателей ВСР	
HRV_SD1SD2	отношение стандартного отклонения перпендикулярно линии идентичности к стандартному отклонению вдоль лини идентичности для графика Пуанкаре
HRV_C1a	вклад ускорения сердечного ритма в кратковременную ВСР
HRV_C2a	вклад ускорения сердечного ритма в долгосрочную ВСР
HRV_IALS	обратная средняя длина сегментов ускорения/замедления
HRV_PSS	процент коротких сегментов
HRV_ApEn	приблизительная энтропия

Продолжение ПРИЛОЖЕНИЯ Б

Продолжение таблицы Б.1

Обозначение признака	Расшифровка
HRV_ShanEn	энтропия Шеннона
HRV_RCMSEn	усовершенствованная композитная мультимасштабная энтропия
HRV_HFD	фрактальная размерность Хигучи
HRV_LZC	сложность Лемпеля-Зива
HRV_DFA_alpha1	показатель краткосрочных корреляций по монофрактальному флуктуационному анализу относительно тренда
HRV_MFDFA_alpha1_Peak	показатель самоподобия сигнала по мультифрактальному флуктуационному анализу относительно тренда
HRV_MFDFA_alpha1_Max	показатель максимального колебания сигнала по мультифрактальному флуктуационному анализу относительно тренда
HRV_MFDFA_alpha1_Asymmetry	показатель ассиметричности мультифрактального спектра по мультифрактальному флуктуационному анализу относительно тренда
Группа частотных признаков	
Hz_0_0.625	относительная мощность сигнала ФПГ в диапазоне частот от 0 до 0.625 Гц
Hz_1.25_1.875	относительная мощность сигнала ФПГ в диапазоне частот от 1.25 до 1.875 Гц
Hz_4.375_5	относительная мощность сигнала ФПГ в диапазоне частот от 4.375 до 5 Гц
Hz_5.625_6.25	относительная мощность сигнала ФПГ в диапазоне частот от 5.625 до 6.25 Гц
Hz_6.25_6.875	относительная мощность сигнала ФПГ в диапазоне частот от 6.25 до 6.875 Гц
Hz_6.875_7.5	относительная мощность сигнала ФПГ в диапазоне частот от 6.875 до 7.5 Гц
Hz_7.5_8.125	относительная мощность сигнала ФПГ в диапазоне частот от 7.5 до 8.125 Гц
Hz_8.125_8.75	относительная мощность сигнала ФПГ в диапазоне частот от 8.125 до 8.75 Гц

Продолжение ПРИЛОЖЕНИЯ Б

Продолжение таблицы Б.1

Обозначение признака	Расшифровка
Hz_0.0375_0.5	относительная мощность сигнала ФПГ в диапазоне частот от 0.0375 до 0.5 Гц
Hz_0.5_1.875	относительная мощность сигнала ФПГ в диапазоне частот от 0.5 до 1.875 Гц

ПРИЛОЖЕНИЕ В

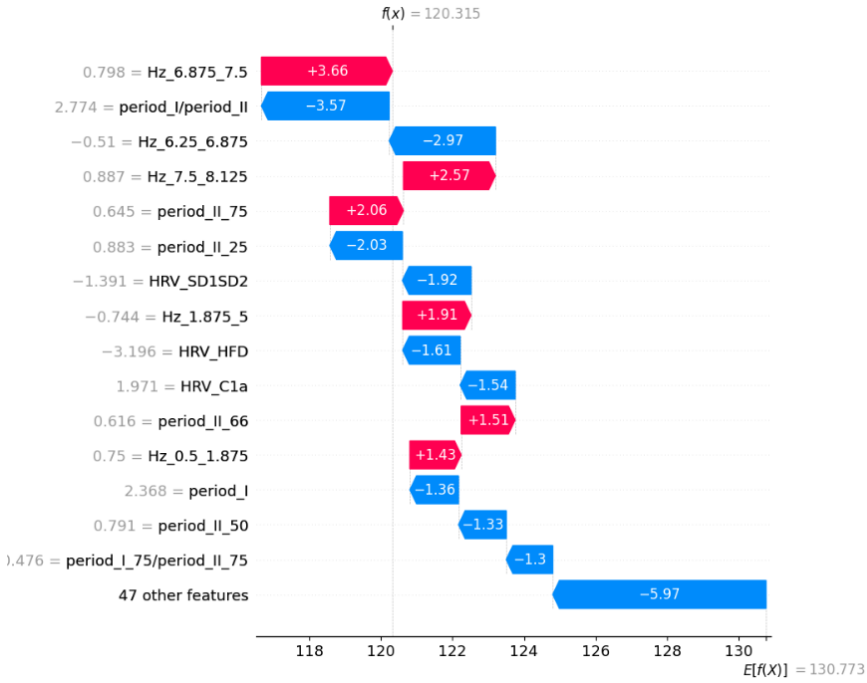

Рисунок В.1 – График SHAP ‘водопад’ модели CatBoost для оценки систолического АД для точки с предсказанным значением 120.315 мм рт. ст. и истинным значением 120.254 мм рт. ст.

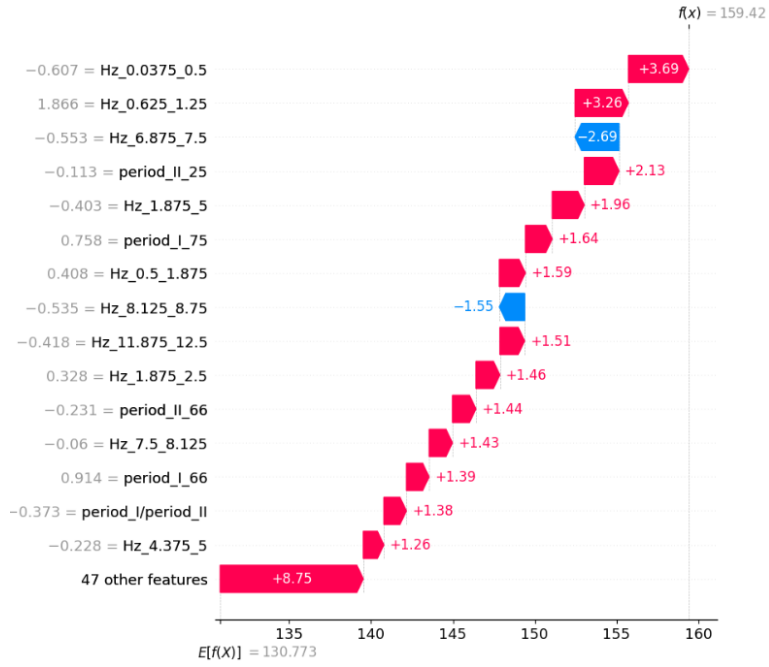

Рисунок В.2 – График SHAP ‘водопад’ модели CatBoost для оценки систолического АД для точки с предсказанным значением 159.420 мм рт. ст. и истинным значением 160.039 мм рт. ст.

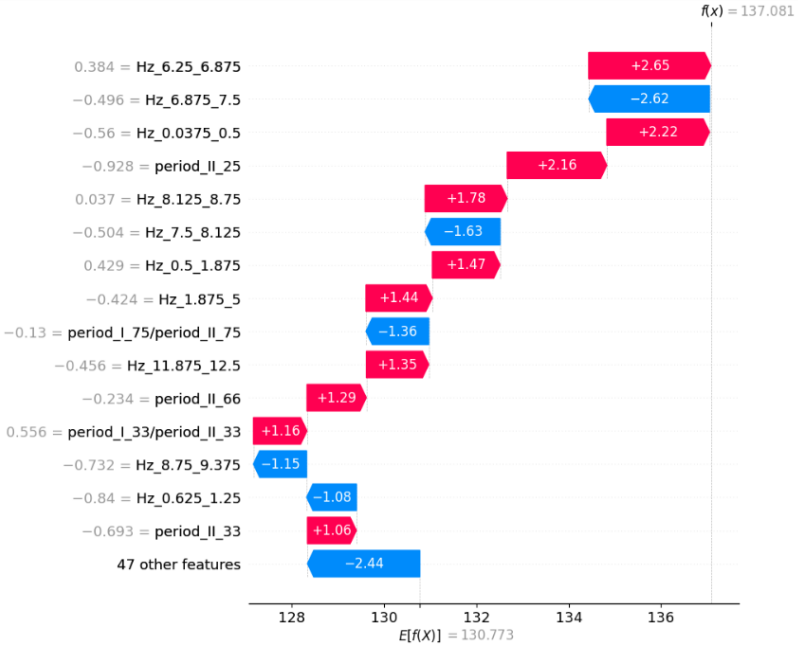

Рисунок В.3 – График SHAP ‘водопад’ модели CatBoost для оценки систолического АД для точки с предсказанным значением 137.081 мм рт. ст. и истинным значением 179.645 мм рт. ст.

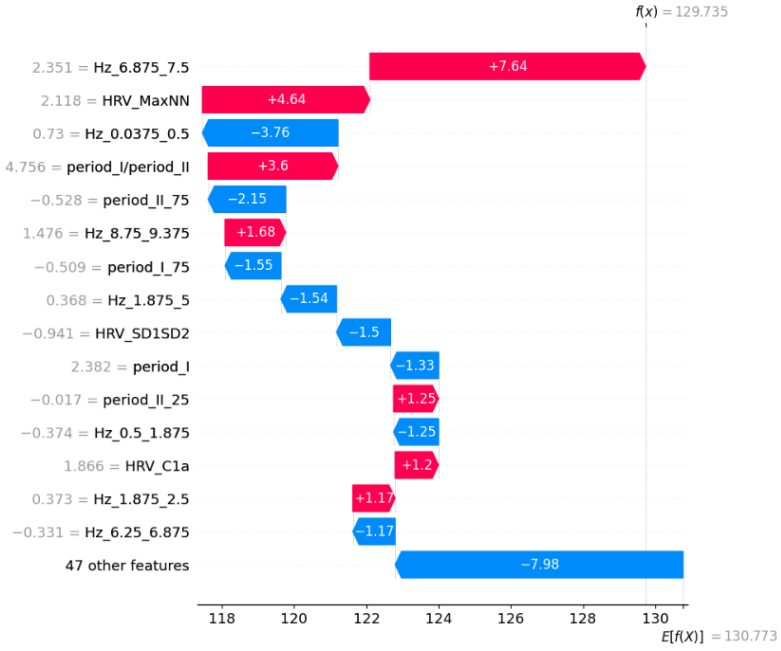

Рисунок В.4 – График SHAP ‘водопад’ модели CatBoost для оценки систолического АД для точки с предсказанным значением 129.735 мм рт. ст. и истинным значением 177.509 мм рт. ст.

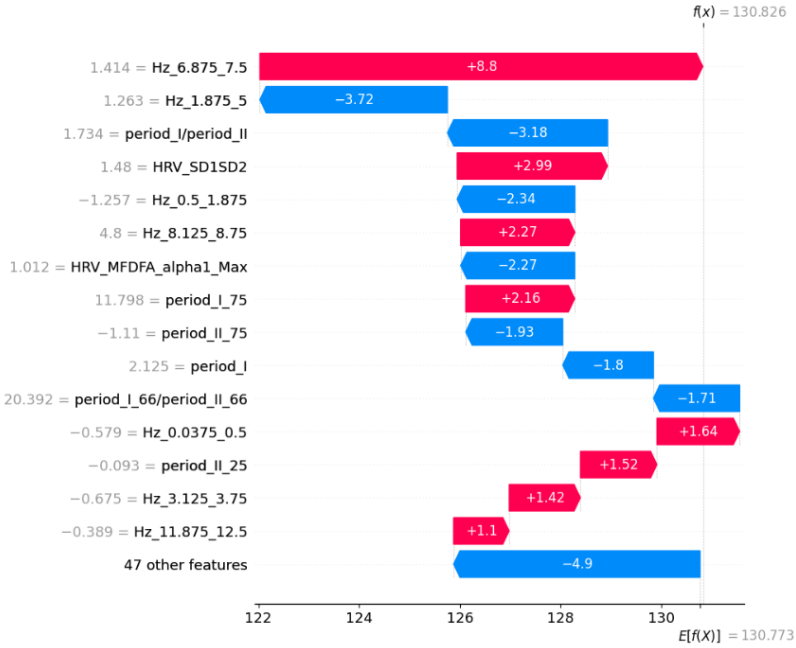

Рисунок В.5 – График SHAP ‘водопад’ модели CatBoost для оценки систолического АД для точки с предсказанным значением 130.826 мм рт. ст. и истинным значением 80.570 мм рт. ст.

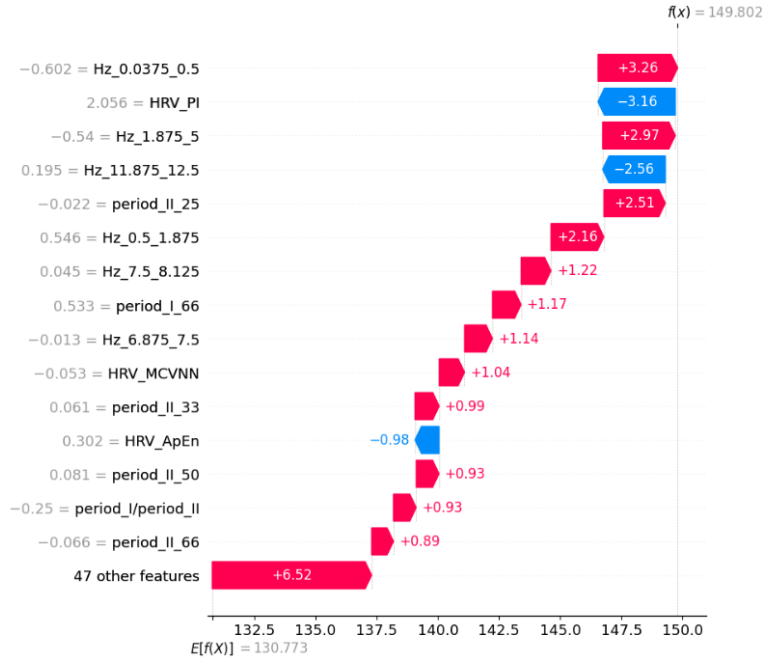

Рисунок В.6 – График SHAP ‘водопад’ модели CatBoost для оценки систолического АД для точки с предсказанным значением 149.802 мм рт. ст. и истинным значением 99.675 мм рт. ст.

ПРИЛОЖЕНИЕ Г

Рисунок Г.1 – График SHAP ‘водопад’ модели CatBoost для оценки диастолического АД для точки с предсказанным значением 76.294 мм рт. ст. и истинным значением 76.936 мм рт. ст.

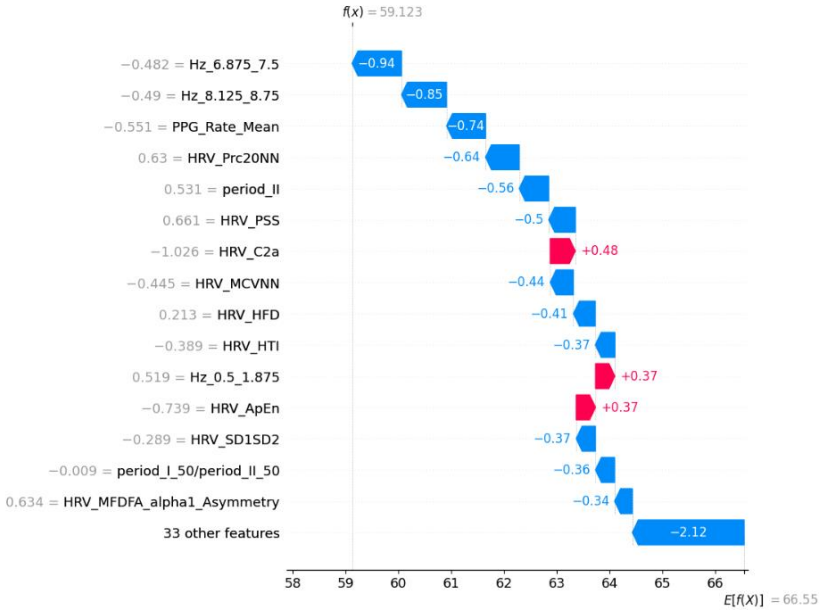

Рисунок Г.2 – График SHAP ‘водопад’ модели CatBoost для оценки диастолического АД для точки с предсказанным значением 59.123 мм рт. ст. и истинным значением 59.041 мм рт. ст

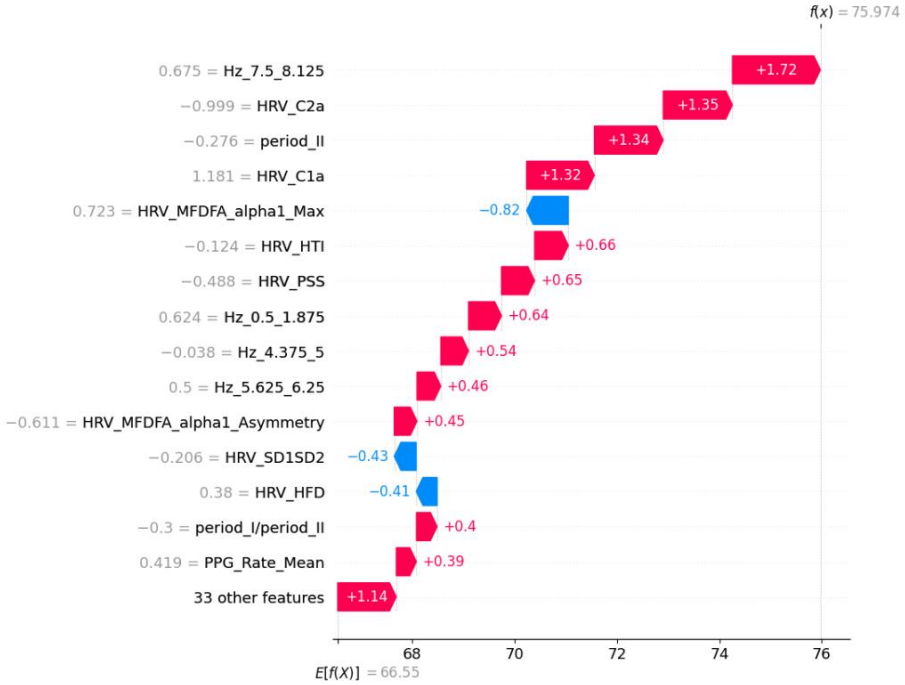

Рисунок Г.3 – График SHAP ‘водопад’ модели CatBoost для оценки диастолического АД для точки с предсказанным значением 75.974 мм рт. ст. и истинным значением 141.039 мм рт. ст.

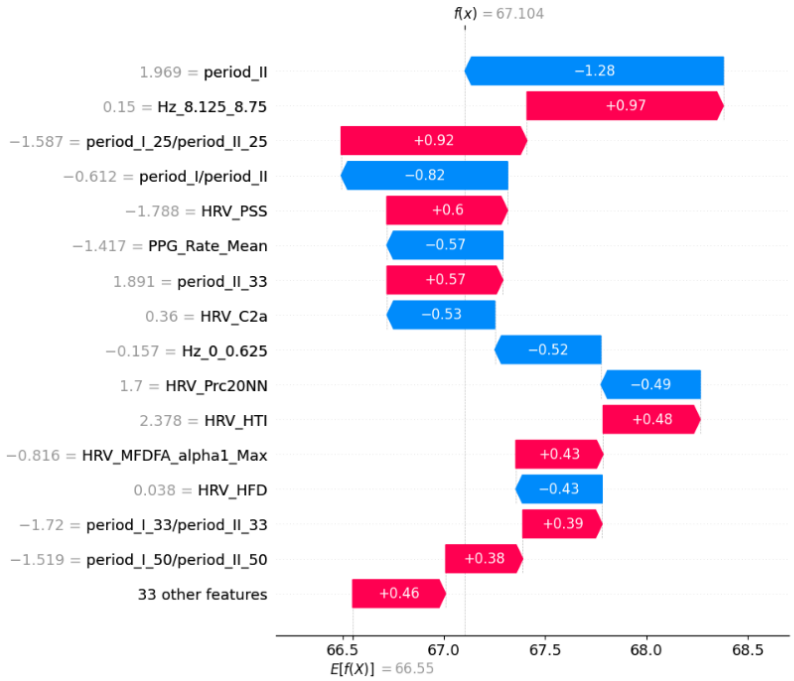

Рисунок Г.4 – График SHAP ‘водопад’ модели CatBoost для оценки диастолического АД для точки с предсказанным значением 67.104 мм рт. ст. и истинным значением 115.964 мм рт. ст.

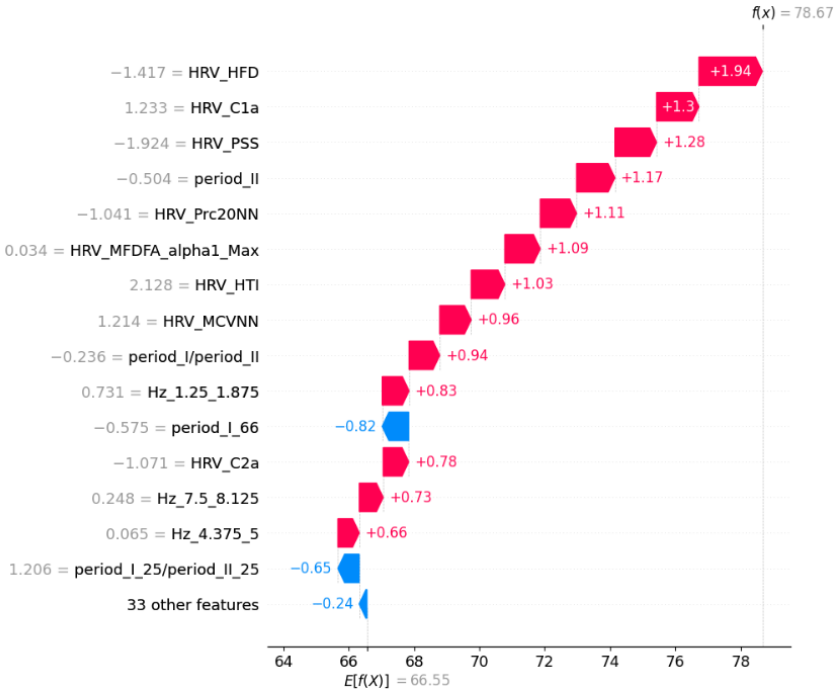

Рисунок Г.5 – График SHAP ‘водопад’ модели CatBoost для оценки диастолического АД для точки с предсказанным значением 78.670 мм рт. ст. и истинным значением 55.546 мм рт. ст.

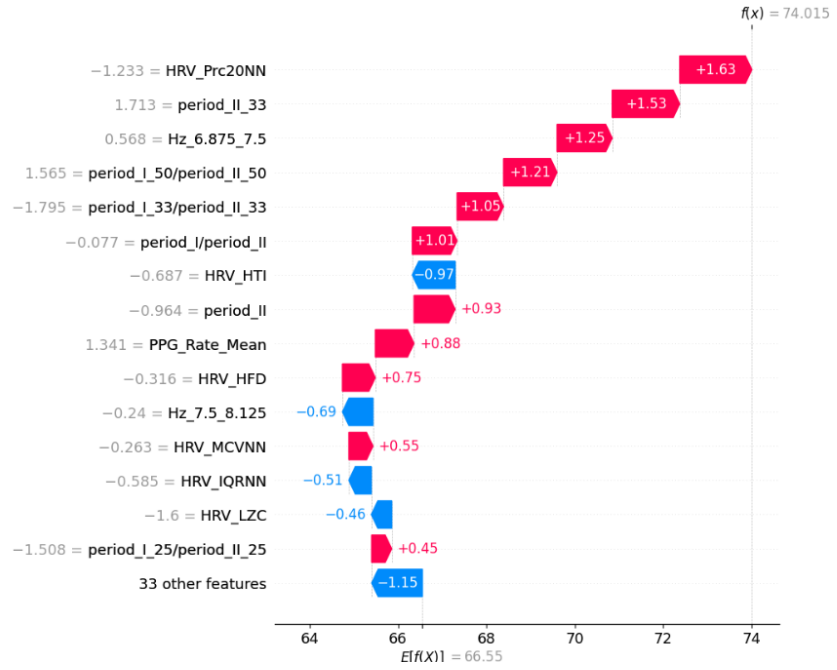

Рисунок Г.6 – График SHAP ‘водопад’ модели CatBoost для оценки диастолического АД для точки с предсказанным значением 74.015 мм рт. ст. и истинным значением 52.834 мм рт. ст.

ПРИЛОЖЕНИЕ Д

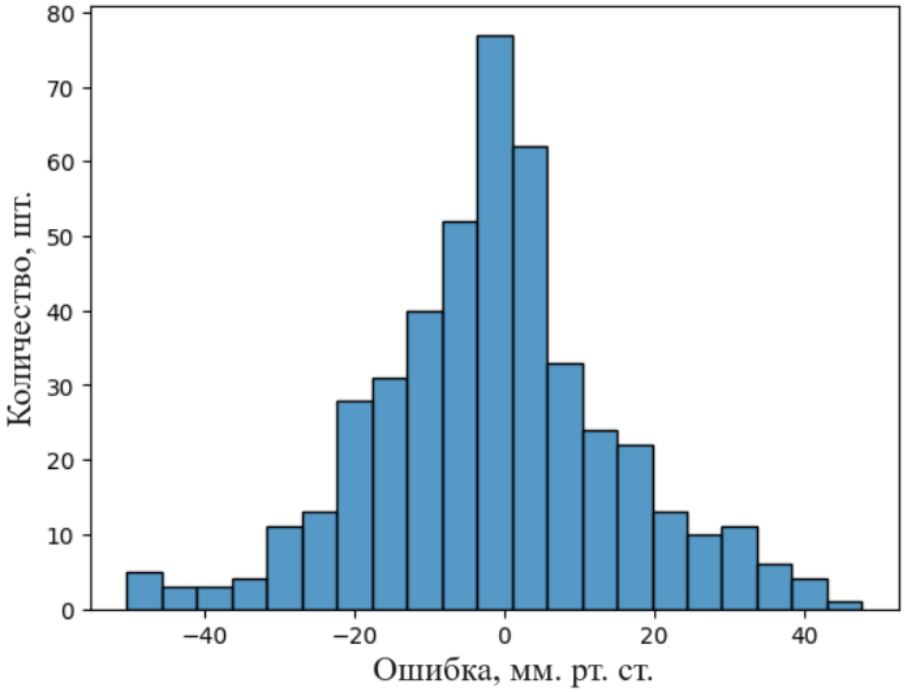

Рисунок Д.1 – Распределение значений для разности между истинным и предсказанным значением для модели CatBoost для предсказания систолического АД

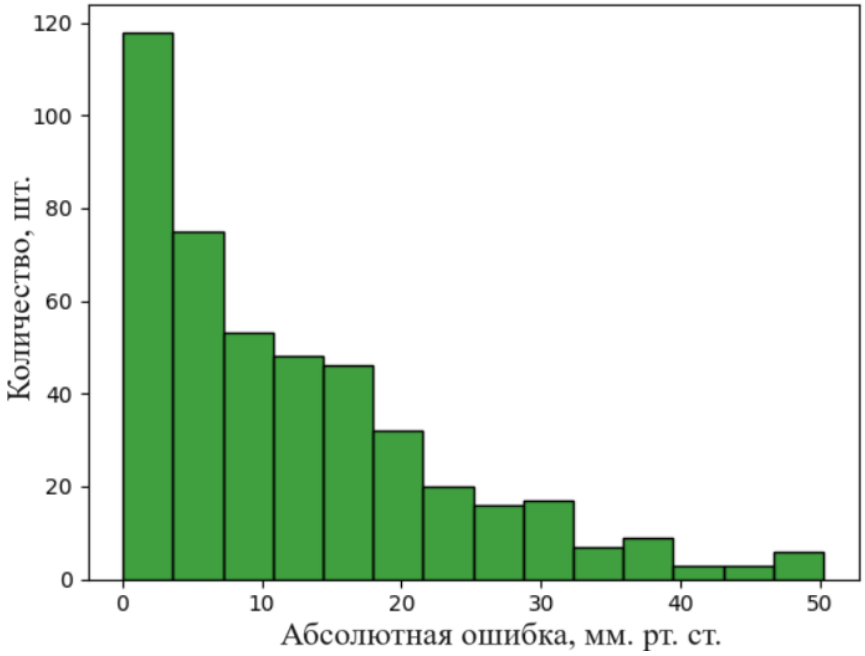

Рисунок Д.2 – Распределение значений для абсолютной разности между истинным и предсказанным значением для модели CatBoost для предсказания систолического АД

ПРИЛОЖЕНИЕ Е

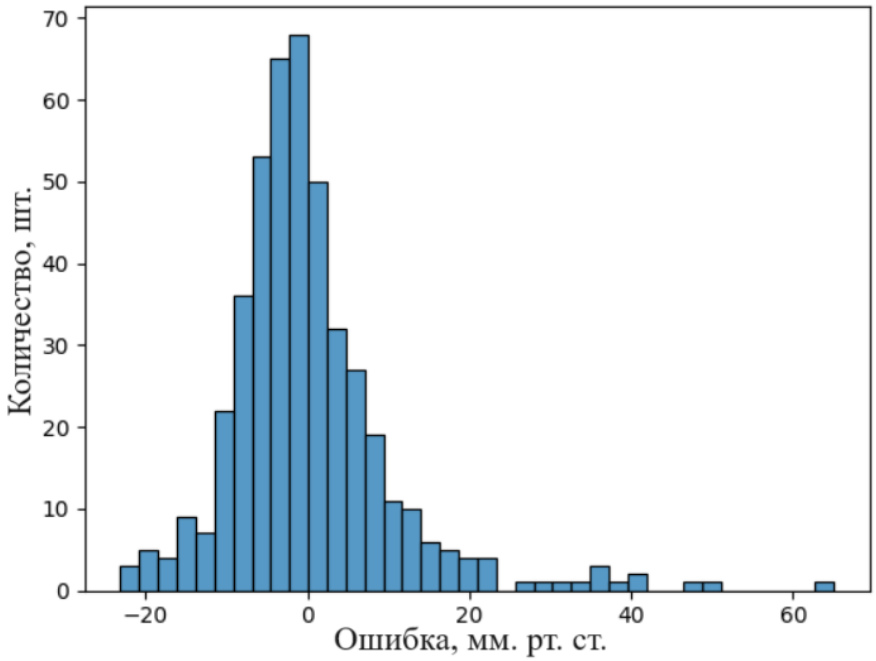

Рисунок Е.1 – Распределение значений для разности между истинным и предсказанным значением для модели CatBoost для предсказания диастолического АД

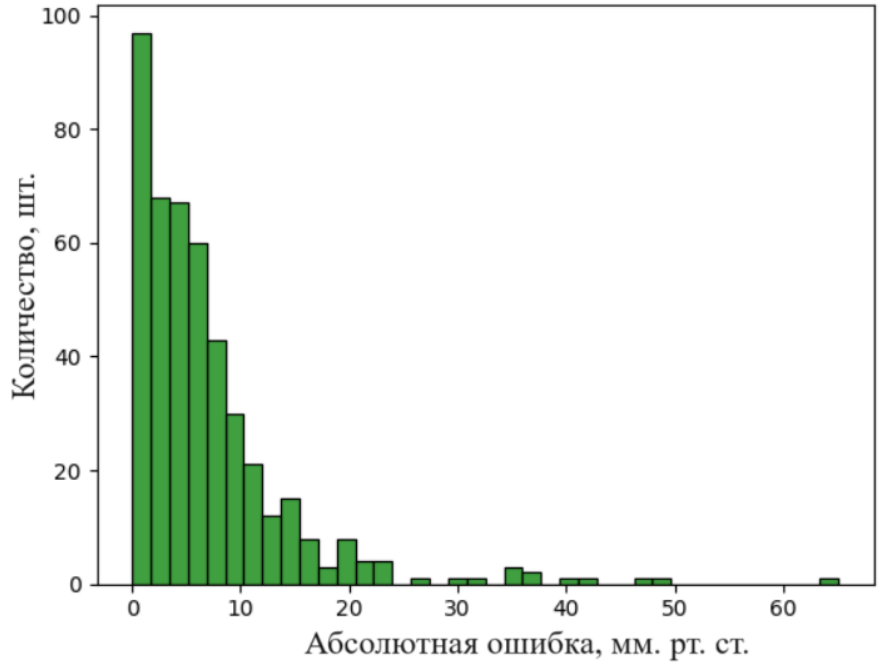

Рисунок Е.2 – Распределение значений для абсолютной разности между истинным и предсказанным значением для модели CatBoost для предсказания диастолического АД