

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  
Базовая кафедра «Аналитика больших данных и методы видеоанализа»

ДОПУСТИТЬ К ЗАЩИТЕ ПЕРЕД ГЭК

/ Зав. кафедрой «АБД и МВ»  
Медведева М.А.  
(подпись) (Ф.И.О.)  
« 02 » июня 2023 г.

**ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА  
(МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ)**

«Сегментация эхокардиографического изображения с применением нейронных сетей»

Научный руководитель: Медведев А.Н.  
с.н.с., к.т.н., доцент

Научный руководитель: Берг Д.Б.  
профессор, д.ф.-м.н., профессор

Студент группы РИМ-210981 Симахин Д.Е

Екатеринбург  
2023

## РЕФЕРАТ

Тема магистерской диссертации:

«Сегментация эхокардиографического изображения с применением нейронных сетей»

Магистерская диссертация выполнена на 80 страницах, содержит 2 таблицы, 28 рисунков, 63 использованных источника.

Актуальность темы диссертационной работы: тема является актуальной, поскольку эхокардиография - это один из наиболее распространенных методов диагностики заболеваний сердца. Это неинвазивный метод, который позволяет получить детальную информацию о структуре и функционировании сердца.

Цель работы: совершенствование метода обучения модели для сегментации эхокардиографических изображений для повышения стабильности работы существующей модели. Под стабильностью подразумевается отсутствие переобучения модели, показание хорошего качества технических метрик на данных, которые модель не видела.

Для выполнения поставленной цели необходимо решение следующих задач:

- Анализ предметной области, исследование современных методов машинного обучения для сегментации эхокардиографических изображений.
- Поиск данных для обучения нейронных сетей и необходимого ПО.
- Разработка нового метода обучения и сравнение его с уже известными.
- Разработка веб-приложения на основе полученного метода.

Объектом исследования – методы машинного обучения, и их применение в сегментации эхокардиографических изображений.

Предмет исследования – разработка нового метода для обучения нейронной сети для сегментации эхокардиографических изображений.

Научная новизна проекта заключается в том, что в работе предлагается усовершенствованный метод обучения, способный повысить стабильность и качество сегментации эхокардиографических изображений.

Практическая значимость заключается в том, что сегментация эхокардиографического изображения с применением нейронных сетей может помочь в медицине в нескольких аспектах. Автоматизация позволяет ускорить процесс приема пациента, при этом не потеряв в качестве сегментации эхокардиографических изображений.

## СОДЕРЖАНИЕ

РЕФЕРАТ .....	2
ВВЕДЕНИЕ .....	6
1 ИССЛЕДОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ СЕГМЕНТАЦИИ ЭХОКАРДИОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЙ .....	7
1.1 Общая характеристика предметной области .....	7
1.2 Анализ современных методов машинного обучения для сегментации изображений .....	9
1.3 Выбор направления исследования .....	24
2 ОБУЧЕНИЕ U-NET ДЛЯ СЕГМЕНТАЦИИ ЭХОКАРДИОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЙ .....	27
2.1 Нейронная сеть U-Net .....	27
2.2 Подбор инструментов разработки .....	30
2.2.1 Выбор библиотеки для обучения нейронной сети .....	30
2.2.2 Выбор платформы для обучения модели .....	32
2.2 Анализ данных для обучения .....	33
2.4 Архитектура U-Net .....	38
2.4.1 Конволюционные нейронные сети .....	38
2.4.2 Максимальное объединение .....	40
2.4.3 Пропускающие соединения .....	41
2.4.4 Функция активации .....	42
2.5 Метрики и интерпретация результатов сегментации .....	43
2.5.1 Dice .....	43
2.5.2 Jaccard .....	45
2.6 Интерпретация результатов работы модели .....	46
2.7 Обучение U-Net .....	48
2.8 Обучение U-Net-fold .....	52
2.9 Итоговое сравнение метрик моделей .....	55
3 ПРИМЕНЕНИЕ МЕТОДА ОБУЧЕНИЯ ДЛЯ СЕГМЕНТАЦИИ ЭХОКАРДИОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЙ .....	57
3.1 Описание бизнес-процесса AS-IS и TO-BE .....	57
3.2 Разработка веб-приложения для эксплуатации .....	59
3.3 Описание проекта .....	62
3.4 Разработка проекта .....	63
3.4.1 Построение дерева задач .....	64

3.4.2 Построение диаграммы Ганта .....	64
3.4.3 Перечень работ по проекту.....	66
3.6 Экономическая эффективность проекта .....	67
ЗАКЛЮЧЕНИЕ.....	70
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ .....	72

## ВВЕДЕНИЕ

Сердечно-сосудистые заболевания являются одной из наиболее распространенных проблем современной медицины, которые могут привести к серьезным осложнениям и даже смерти. Эхокардиография - метод, основанный на использовании ультразвука для получения изображения сердца, широко используется для диагностики и лечения этих заболеваний. Однако, обработка полученных изображений может быть сложной задачей, особенно при необходимости получения информации о состоянии определенных сегментов сердца [1].

В данной работе будет рассмотрена тема "Сегментация эхокардиографического изображения с применением нейронных сетей". В работе будут рассмотрены основные методы сегментации изображений сердца, а также проведен анализ эффективности применяемых методов. Будет рассмотрено использование нейронных сетей для автоматической сегментации изображений сердца, а также возможность применения этого подхода в клинической практике.

Для достижения этой цели будут поставлены следующие задачи: изучение основных методов сегментации изображений сердца, анализ их преимуществ и недостатков; разработка метода автоматической сегментации на основе нейронных сетей; проведение экспериментальных исследований для оценки эффективности разработанного метода.

Результаты данной работы могут быть использованы в клинической практике для диагностики и лечения заболеваний сердечно-сосудистой системы. Разработанный метод автоматической сегментации с использованием нейронных сетей может значительно ускорить процесс диагностики и повысить точность получаемых результатов, что в свою очередь может способствовать более эффективному лечению пациентов.

# 1 ИССЛЕДОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ СЕГМЕНТАЦИИ ЭХОКАРДИОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЙ

## 1.1 Общая характеристика предметной области

Для анализа библиометрических показателей области исследования "Сегментация эхокардиографического изображения с применением нейронных сетей" была проведена поисковая выдача в базе данных Scopus. Были выбраны ключевые слова "echocardiography", "deep learning", "Ultrasound Image", "medicine". В качестве периода был выбран 2017-2021 годы.

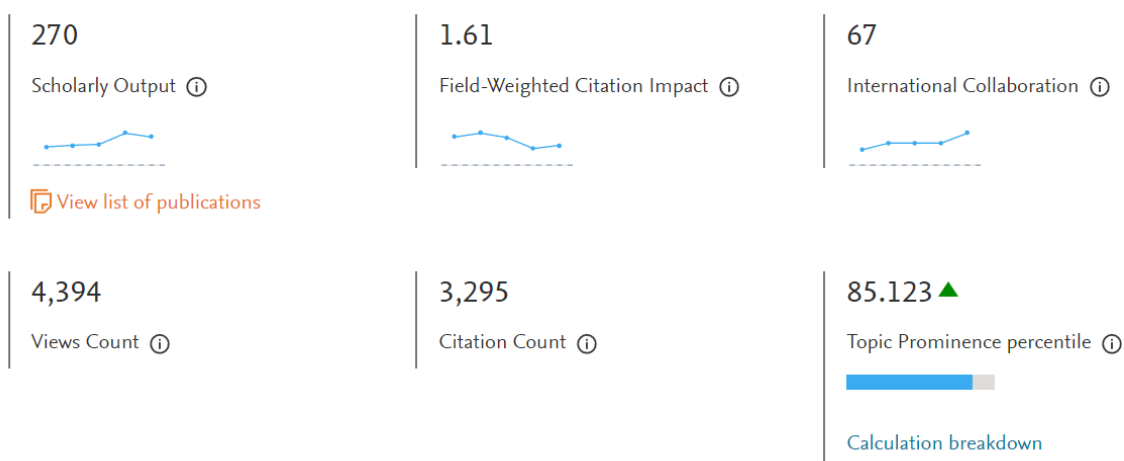


Рисунок 1 – Библиометрические показатели по кластеру (Ultrasound Image; Diagnostic Imaging; Deep learning)

Обозначения библиометрических показателей по кластеру [2]:

- Scholarly output (научный результат) - это количество научных работ, опубликованных автором или группой авторов в научных журналах, книгах и других публикациях. Их количество немного снижается по причине отсутствия новых алгоритмов машинного обучения.
- Views count (количество просмотров) - это количество просмотров статьи, видео или другого контента, связанного с научным результатом.
- Citation output (цитирование) - это количество раз, когда научный результат



## 1.2 Анализ современных методов машинного обучения для сегментации изображений

Выполнен обзор и анализ литературных источников по вопросу сегментации эхокардиографических изображений.

*ResDUnet: Residual Dilated UNet for Left Ventricle Segmentation from Echocardiographic Images* Amer, A./ Ye, X./ Zolgharni, M./ Janan, F.

Статья "ResDUnet: Residual Dilated UNet for Left Ventricle Segmentation from Echocardiographic Images" описывает новый метод для сегментации левого желудочка на эхокардиографических изображениях. Авторы статьи предлагают использовать модель ResDUnet, которая объединяет в себе две популярные архитектуры нейронных сетей: UNet и ResNet.

ResNet - это глубокая нейронная сеть, которая использует блоки с остаточным подключением для борьбы с проблемой затухания градиентов при обучении глубоких моделей. Блоки с остаточным подключением позволяют сохранять информацию из предыдущих слоев и передавать ее в следующие слои.

Модель ResDUnet использует блоки с остаточным подключением и дополнительно включает в себя дилатационные свертки, которые увеличивают размер поля зрения нейронной сети. Это позволяет модели сегментировать объекты на изображениях с большим разрешением с высокой точностью.

Авторы статьи провели эксперименты на наборе данных, состоящем из 200 эхокардиографических изображений. Результаты показали, что модель ResDUnet превзошла другие методы сегментации левого желудочка по точности и скорости работы.

*Generalizable fully automated multi-label segmentation of four-chamber view echocardiograms based on deep convolutional adversarial networks*  
Arafati, A./ Morisawa, D./ Avendi, M.R./ Amini, M.R./ Assadi, R.A./ Jafarkhani, H./

*Kheradvar, A.*

В статье "Обобщаемая полностью автоматизированная сегментация четырехкамерных эхокардиограмм с несколькими метками на основе глубоких сверточных связательных сетей" обсуждается разработка полностью автоматизированной системы сегментации четырехкамерных эхокардиограмм с использованием глубоких сверточных связательных сетей (DCANS).

Авторы начинают с того, что подчеркивают важность точной сегментации при эхокардиографии для диагностики и мониторинга сердечно-сосудистых заболеваний. Затем они вводят концепцию DCAN, которые представляют собой алгоритмы глубокого обучения, которые можно обучить выполнению задач сегментации изображений.

Далее в статье описывается методология, использованная для разработки автоматизированной системы сегментации, включая использование большого набора данных эхокардиограмм для обучения DCAN. Авторы также обсуждают оценку производительности системы с использованием различных показателей, таких как коэффициент подобия кубиков и расстояние Хаусдорфа.

В заключение статьи подчеркиваются потенциальные преимущества автоматизированной системы сегментации, такие как уменьшение вариабельности между различными операторами и повышение эффективности в клинической практике. Авторы отмечают, что необходимы дальнейшие исследования для подтверждения эффективности системы на различных типах эхокардиограмм и в различных группах пациентов.

*Congestive heart failure waveform classification based on short time-step analysis with recurrent network*

*Darmawahyuni, A./ Nurmaini, S./ Yuwandini, M./ Muhammad Naufal Rachmatullah/ Firdaus, F./ Tutuko, B.*

В статье "Классификация сигналов застойной сердечной недостаточности на основе анализа с короткими временными шагами с использованием

рекуррентной сети" обсуждается исследование по использованию искусственного интеллекта (ИИ) для классификации сигналов застойной сердечной недостаточности (ХСН). Авторы начинают с описания ХСН и важности раннего выявления и точной диагностики.

Исследование сосредоточено на использовании рекуррентной нейронной сети (RNN) для классификации сигналов СНФ на основе анализа с короткими временными шагами. Авторы объясняют методологию и данные, использованные в исследовании, которое включало сбор сигналов электрокардиограммы (ЭКГ) от пациентов с ХСН и здоровых людей.

Результаты исследования показали, что RNN смог точно классифицировать сигналы ХСН с высокой степенью чувствительности и специфичности. Авторы обсуждают потенциальные возможности применения этого инструмента искусственного интеллекта в клинической практике, такие как повышение точности и эффективности диагностики ХСН.

В заключение статьи подчеркивается важность дальнейших исследований в этой области и необходимость сотрудничества между клиницистами и экспертами по искусственному интеллекту. В целом, исследование демонстрирует потенциал искусственного интеллекта в улучшении диагностики и лечения ХСН, что в конечном итоге приводит к улучшению результатов лечения пациентов.

*MFP-Unet: A novel deep learning based approach for left ventricle segmentation in echocardiography.* Moradi, S./ Oghli, M.G./ Alizadehasl, A./ Shiri, I./ Oveisi, N./ Oveisi, M./ Maleki, M./ Dhooge, J

Статья "MFP-Unet: A novel deep learning based approach for left ventricle segmentation in echocardiography" описывает новый метод для сегментации левого желудочка на эхокардиографических изображениях. Авторы статьи предлагают использовать модель MFP-Unet, которая объединяет в себе две популярные архитектуры нейронных сетей: UNet и Multi-Feature Fusion (MFF).

MFF - это архитектура нейронной сети, которая объединяет несколько признаковых карт в единую карту. Это позволяет модели использовать

информацию из разных уровней абстракции, что может улучшить точность сегментации.

Модель MFP-Unet использует UNet для извлечения признаков из входного изображения и MFF для объединения признаков карт. Также авторы статьи предлагают использовать дополнительные сверточные слои для улучшения точности сегментации.

*Deep learning-based algorithm for detecting aortic stenosis using electrocardiography*

*Kwon, J.-M./ Lee, S.Y./ Jeon, K.-H./ Lee, Y./ Kim, K.-H./ Park, J./ Oh, B.-H./ Lee, M.-M.*

Статья "Deep learning-based algorithm for detecting aortic stenosis using electrocardiography" описывает новый алгоритм для диагностики стеноза аорты с использованием электрокардиографии (ЭКГ). Авторы статьи предлагают использовать глубокое обучение для автоматического анализа ЭКГ и определения наличия стеноза аорты.

Авторы статьи разработали нейронную сеть, которая состоит из двух сверточных слоев и полносвязного слоя. Нейронная сеть обучалась на большом наборе данных, состоящем из ЭКГ-записей пациентов с и без стеноза аорты.

Для тестирования алгоритма авторы использовали набор данных, состоящий из 1000 ЭКГ-записей пациентов. Результаты показали, что алгоритм имеет высокую точность в диагностике стеноза аорты, превышающую точность диагностики, основанной на экспертном мнении кардиологов.

Авторы статьи считают, что их алгоритм может быть использован в клинической практике для быстрой и точной диагностики стеноза аорты. Он может быть особенно полезен в ситуациях, когда нет доступа к дополнительным методам диагностики, таким как эхокардиография.

*Machine Learning in Fetal Cardiology: What to Expect*

В кардиологии плода доказано, что визуализация (особенно

эхокардиография) помогает в диагностике и мониторинге плодов с нарушенной сердечно-сосудистой системой, потенциально связанной с несколькими состояниями плода. В настоящее время для оценки структуры и функции сердца плода используются различные ультразвуковые подходы, включая, среди прочего, традиционную двухмерную визуализацию и М-режим, а также тканевую доплеровскую визуализацию. Однако оценка состояния сердца плода по-прежнему остается сложной задачей, главным образом из-за произвольных движений плода, небольшого размера сердца и отсутствия опыта в эхокардиографии плода у некоторых сонографистов. Таким образом, использование новых технологий для улучшения первичных полученных изображений, для извлечения результатов измерений или для помощи в диагностике сердечных аномалий имеет большое значение для оптимальной оценки состояния сердца плода. Машинное обучение (ML) - это дисциплина в области информатики, ориентированная на обучение компьютера выполнению задач с определенными целями без явного программирования правил выполнения этой задачи. В этом обзоре мы предоставляем краткий обзор потенциала методов ML для улучшения оценки сердечной функции плода за счет оптимизации получения изображений и количественной оценки / сегментации, а также помощи в улучшении пренатальной диагностики ремоделирования и аномалий сердца плода.

*3D MRI with CT-like bone contrast – An overview of current approaches and practical clinical implementation*

*Chong, L.R./ Lee, K./ Sim, F.Y.*

В статье "3D-MPT с контрастированием костей, подобным компьютерной томографии (КТ) – обзор современных подходов и практическая клиническая реализация" представлен обзор современных подходов и практическая клиническая реализация 3D-магнитно-резонансной томографии (МРТ) с контрастированием костей, подобным компьютерной томографии (КТ).

Авторы начинают с обсуждения ограничений традиционной МРТ в

визуализации костных структур, которые лучше видны на компьютерной томографии. Затем они представляют концепцию 3D-MPT с контрастированием костей, подобным компьютерной томографии, которая использует различные методы для улучшения видимости костных структур на МРТ-изображениях.

Далее в статье описываются различные подходы к достижению КТ-подобного контрастирования костей при МРТ, включая использование специализированных импульсных последовательностей, контрастных веществ и методов постобработки изображений. Авторы также обсуждают практические соображения по внедрению этой технологии в клиническую практику, такие как требования к оборудованию, подготовка пациента и интерпретация изображений.

В заключение статьи подчеркиваются потенциальные преимущества 3D-MPT с контрастированием костей, подобным компьютерной томографии, такие как снижение лучевой нагрузки на пациентов и предоставление более полного представления об анатомических структурах. Авторы отмечают, что необход

*Artificial Intelligence in Precision Cardiovascular Medicine Krittanawong, C./ Zhang, H./ Wang, Z./ Aydar, M./ Kitai, T.*

Методы искусственного интеллекта были применены в сердечно-сосудистой медицине для изучения новых генотипов и фенотипов существующих заболеваний, улучшения качества ухода за пациентами, обеспечения экономической эффективности и снижения показателей повторной госпитализации и смертности. За последнее десятилетие для диагностики и прогнозирования сердечно-сосудистых заболеваний было использовано несколько методов машинного обучения. Каждая проблема требует определенной степени понимания проблемы с точки зрения сердечно-сосудистой медицины и статистики, чтобы применить оптимальный алгоритм машинного обучения. В ближайшем будущем искусственный интеллект

приведет к сдвигу парадигмы в сторону точной сердечно-сосудистой медицины. Потенциал искусственного интеллекта в сердечно-сосудистой медицине огромен; однако незнание проблем может затмить его потенциальное клиническое воздействие. В этой статье дается общее представление о применении искусственного интеллекта в клинической помощи при сердечно-сосудистых заболеваниях и обсуждается его потенциальная роль в содействии прецизионной сердечно-сосудистой медицине.

*Cardiac VFM visualization and analysis based on YOLO deep learning model and modified 2D continuity equation Zhuang, Z./ Liu, G./ Ding, W./ Raj, A.N.J./ Qiu, S./ Guo, J./ Yuan, Y.*

Другая статья, "Cardiac VFM visualization and analysis based on YOLO deep learning model and modified 2D continuity equation", описывает новый метод визуализации и анализа данных о сердце с использованием глубокого обучения.

Авторы статьи предлагают использовать модифицированное уравнение непрерывности вместе с нейронной сетью YOLO для анализа данных о кровотоке в сердце. Этот метод позволяет получить визуализацию трехмерной модели сердца, а также оценить параметры кровотока, такие как скорость и объем.

Для тестирования метода авторы использовали данные о кровотоке в сердце, полученные с помощью магнитно-резонансной томографии (МРТ). Результаты показали, что метод имеет высокую точность и может быть использован для диагностики различных заболеваний сердца, таких как митральный стеноз и аортальный стеноз.

Авторы статьи считают, что их метод может быть использован в клинической практике для более точной диагностики и лечения заболеваний сердца. Он также может быть полезен для исследований в области кардиологии и разработки новых методов лечения.

*LU-Net: A Multistage Attention Network to Improve the Robustness of*

*Segmentation of Left Ventricular Structures in 2-D Echocardiography* Leclerc, S./ Smistad, E. | Østvik, A. | Cervenansky, F.

Статья "LU-Net: A Multistage Attention Network to Improve the Robustness of Segmentation of Left Ventricular Structures in 2-D Echocardiography" описывает новый метод сегментации левых желудочков сердца на изображениях, полученных при помощи 2D-эхокардиографии.

Авторы статьи предлагают использовать многоступенчатую нейронную сеть с механизмом внимания для улучшения точности сегментации левых желудочков. Этот метод позволяет автоматически определять границы левых желудочков на изображениях, что упрощает диагностику заболеваний сердца и позволяет более точно оценивать их степень тяжести.

Для тестирования метода авторы использовали данные, полученные при помощи 2D-эхокардиографии у пациентов с различными заболеваниями сердца. Результаты показали, что метод имеет высокую точность и может быть использован для диагностики различных заболеваний сердца, таких как дилатация левого желудочка и гипертрофия миокарда.

*Systematic Quantification of Sources of Variation in Ejection Fraction Calculation Using Deep Learning*, Yuan, N. | Jain, I. | Rattehalli, N. | He, B. | Pollick, C. | Liang, D. | Heidenreich, P. | Zou, J. | Cheng, S. | Ouyang, D.

Данная статья представляет собой исследование, которое описывает систематическое количественное измерение источников вариации в расчете фракции выброса (EF) с использованием глубокого обучения. В работе рассматривается вопрос о том, как различные факторы могут влиять на точность расчета EF, и как можно использовать глубокое обучение для определения этих факторов.

В исследовании были использованы данные, полученные из множества источников, включая медицинские центры и базы данных. Для анализа данных была использована глубокая нейронная сеть, которая была обучена на основе большого количества изображений сердца. С помощью этой сети были проанализированы различные факторы, которые могут влиять на точность

расчета EF, такие как тип изображения, качество изображения, метод расчета EF и другие.

В результате исследования было выявлено несколько факторов, которые могут влиять на точность расчета EF. Одним из таких факторов является тип изображения, который может сильно влиять на точность расчета EF. Также было выявлено, что качество изображения может оказывать значительное влияние на точность расчета EF.

В целом, данное исследование представляет собой значимый вклад в развитие методов расчета EF с использованием глубокого обучения. Результаты исследования могут быть использованы для улучшения точности расчета EF и повышения качества диагностики сердечно-сосудистых заболеваний.

*Fast and accurate view classification of echocardiograms using deep learning*  
Madani, A./ Arnaout, R./ Mofrad, M./ Arnaout, R.

Статья "Fast and accurate view classification of echocardiograms using deep learning" описывает новый метод классификации изображений, полученных при помощи эхокардиографии, с использованием глубокого обучения.

Авторы статьи предлагают использовать сверточную нейронную сеть для автоматической классификации изображений сердца на основе их типа (апикальное четырехкамерное, апикальное двухкамерное и т.д.). Этот метод позволяет быстро и точно определять тип изображения, что упрощает диагностику заболеваний сердца и позволяет более эффективно использовать время специалистов.

Для тестирования метода авторы использовали данные, полученные при помощи эхокардиографии у пациентов с различными заболеваниями сердца. Результаты показали, что метод имеет высокую точность и может быть использован для классификации различных типов изображений сердца.

*Deep Learning for Segmentation Using an Open Large-Scale Dataset in 2D Echocardiography* Leclerc, S./ Smistad, E./ Pedrosa, J./ Ostvik, A./ Cervenansky, F./ Espinosa, F./ Espeland, T./ Berg, E.A.R./

Для тестирования метода авторы использовали открытый крупномасштабный набор данных, содержащий более 20 000 изображений сердца. Результаты показали, что метод имеет высокую точность и может быть использован для сегментации различных структур сердца.

*MV-RAN: Multiview recurrent aggregation network for echocardiographic sequences segmentation and full cardiac cycle analysis* Li, M./ Wang, C./ Zhang, H./ Yang, G

Статья "MV-RAN: Multiview recurrent aggregation network for echocardiographic sequences segmentation and full cardiac cycle analysis" описывает новый метод сегментации и анализа эхокардиографических последовательностей, который использует многопредставленную рекуррентную агрегационную сеть. Этот метод позволяет быстро и точно определять границы структур на последовательностях и анализировать изменения в течение полного цикла сердечной деятельности. Результаты тестирования показали, что метод имеет высокую точность и может быть использован в клинической практике для более точной диагностики заболеваний сердца и мониторинга лечения.

*D MRI with CT-like bone contrast – An overview of current approaches and practical clinical implementation*

Данная статья обзорно рассматривает текущие подходы и практическую клиническую реализацию 3D МРТ с контрастом, аналогичным контрасту на КТ, для визуализации костей. Описываются различные техники и алгоритмы, используемые для улучшения контрастности костей на МРТ изображениях, такие как использование специальных последовательностей импульсов, различных типов конструкций катушек и алгоритмов реконструкции. Также обсуждаются преимущества и недостатки каждого метода и его практическое применение в клинической практике. В целом, статья дает обзор текущего состояния и перспектив развития 3D МРТ с контрастом, аналогичным контрасту на КТ, для визуализации костей.

*Overview of the Whole Heart and Heart Chamber Segmentation Methods*

*Habijan, M./ Babin, D./ Galić, I./ Leventić, H./ Romić, K./ Velicki, L./ Pižurica, A.*

Обзор методов сегментации всего сердца и отдельных камер сердца, которые используются для анализа эхокардиографических последовательностей. В обзоре рассматриваются различные подходы, такие как методы на основе графов, методы на основе моделей, методы на основе глубокого обучения и другие. Каждый из этих методов имеет свои преимущества и недостатки, и выбор определенного метода зависит от конкретной задачи и доступных данных.

*Steps to use artificial intelligence in echocardiography*

*Kusunose, K.*

В статье Кусуносе "Шаги по использованию искусственного интеллекта в эхокардиографии" автор обсуждает потенциальные области применения искусственного интеллекта (ИИ) в области эхокардиографии. Статья начинается с освещения проблем, связанных с интерпретацией эхокардиограмм, таких как необходимость специальной подготовки и субъективный характер интерпретации.

Затем автор знакомит с концепцией искусственного интеллекта и его потенциалом для повышения точности и эффективности интерпретации эхокардиограммы. В статье обсуждаются различные методы искусственного интеллекта, такие как машинное обучение и deep learning, и их потенциальное применение в эхокардиографии.

Автор также освещает некоторые текущие исследования в этой области, такие как использование искусственного интеллекта для выявления сердечных аномалий и прогнозирования исходов у пациентов с заболеваниями сердца. В статье подчеркивается важность сотрудничества между клиницистами и экспертами по искусственному интеллекту при разработке и внедрении инструментов искусственного интеллекта в клиническую практику.

В целом, в статье представлен всесторонний обзор потенциальных применений искусственного интеллекта в эхокардиографии и подчеркивается необходимость дальнейших исследований в этой области. Автор

предполагает, что искусственный интеллект обладает потенциалом произвести революцию в области эхокардиографии и улучшить результаты лечения пациентов.

*Improving ultrasound video classification: An evaluation of novel deep learning methods in echocardiography*

*Huang, Y./ Xia, W./ Lu, Z./ Liu, Y./ Chen, H./ Zhou, J./ Fang, L./ Zhang, Y.*

Статья "Улучшение классификации ультразвуковых видеозаписей: оценка новых методов глубокого обучения в эхокардиографии" Хуанга и др. основное внимание уделяется применению методов глубокого обучения в области эхокардиографии, в частности при классификации ультразвуковых видеозаписей. Авторы отмечают, что в то время как традиционные методы машинного обучения использовались в прошлом, методы глубокого обучения показали многообещающие результаты в повышении точности классификации.

Статья начинается с обсуждения проблем, связанных с классификацией ультразвуковых видеозаписей в эхокардиографии, таких как вариабельность качества изображения и различия в анатомии сердца у разных пациентов. Затем авторы представляют предложенные ими модели глубокого обучения, которые включают в себя трехмерную сверточную нейронную сеть (CNN) и трехмерную пространственно-временную CNN. Модели были обучены на наборе данных из 1000 ультразвуковых видеозаписей и оценены с использованием различных показателей, таких как точность и площадь под кривой рабочих характеристик приемника (AUC-ROC).

Результаты показали, что 3D пространственно-временная CNN превосходит 3D CNN и традиционные методы машинного обучения с точки зрения точности и AUC-ROC. Авторы также провели эксперименты, чтобы оценить устойчивость моделей к изменениям качества изображений, и обнаружили, что методы глубокого обучения были более надежными, чем традиционные методы.

В целом, в статье подчеркивается потенциал методов глубокого обучения

в повышении точности классификации ультразвуковых видеоизображений при эхокардиографии. Авторы предполагают, что эти методы могли бы быть использованы в клинических условиях для оказания помощи в диагностике и лечении сердечных заболеваний.

*Congestive heart failure waveform classification based on short time-step analysis with recurrent network Darmawahyuni, A./ Nurmaini, S./ Yuwandini, M./ Muhammad Naufal Rachmatullah/ Firdaus, F./ Tutuko, B.*

Статья "Congestive heart failure waveform classification based on short time-step analysis with recurrent network" описывает метод классификации эхокардиографических последовательностей для диагностики сердечной недостаточности.

В настоящей статье предлагаются методы глубокого обучения - рекуррентные нейронные сети (RNNS) с архитектурой долговременной кратковременной памяти (LSTM) — для создания диагностического алгоритма, который обеспечивает высокую точность при ограниченной информации и автоматизированном извлечении признаков. Сигналы ЭКГ, использованные в этом исследовании, были получены из общедоступных баз данных PhysioNet. В статье точно настроили гиперпараметры 24 моделей LSTM, чтобы получить наилучшую модель. Кроме того, сегментация сигнала ЭКГ сравнивалась в течение первых пяти и пятнадцати минут в качестве признаков. Из 24 моделей LSTM модель с первыми пятнадцатиминутными сигналами ЭКГ (модель 1) получила наивысшую точность, чувствительность, специфичность, прецизионность и оценку F1 (99.86%, 99.85%, 99.85%, 99.87%, и 99,86% соответственно). Первые пятнадцать минут сигналы ЭКГ работали хорошо, потому что модель LSTM изучала все большее число функций. В заключение, предложенная модель LSTM могла бы дать клиницисту предварительный диагноз ХСН для дальнейшего медицинского вмешательства. Глубокое обучение может быть полезным методом прогнозирования для увеличения числа выявленных пациентов с ХСН.

В ходе исследования по теме сегментация эхокардиографического изображения с применением нейронных сетей было исследовано более 50 патентов, ключевыми словами которых были: «U-Net», «сегментация», «метод обучения». В результате анализа были найдены 3 патента, которые наиболее близко передают суть представляемой в данной работе разработки.

В патенте [7] рассматривается алгоритм обработки изображений, который увеличивает точность при обучении U-Net. Также в работе изложен способ формирования функции потерь для обучения сверточной нейронной сети для восстановления изображения. Несмотря на подробное описание алгоритмов обработки изображений и способа формирования функции потерь, патент не представляет подхода, оптимизирующего переобучение и скорость обучения модели.

В работе [8] представлен способ автоматической классификации рентгеновских изображений с использованием масок прозрачности

Технический результат заключается в увеличении точности распознавания областей интереса при анализе графической информации. Такой результат достигается способом автоматической классификации рентгеновских изображений с использованием масок прозрачности, который предусматривает формирование рентгеновского цифрового изображения в виде матрицы оптических плотностей объекта, получение глубинных слоев изображения путем обработки исходного цифрового изображения локальными фильтрами, уникальными для каждого слоя, снижение размерности изображений в глубинных слоях посредством технологии пулинга (субдискретизации), формирование пространства информативных признаков для обучаемой полносвязной нейронной сети из субдискретизированных глубинных слоев и классификацию полученного вектора информативных признаков посредством полносвязной нейронной сети.

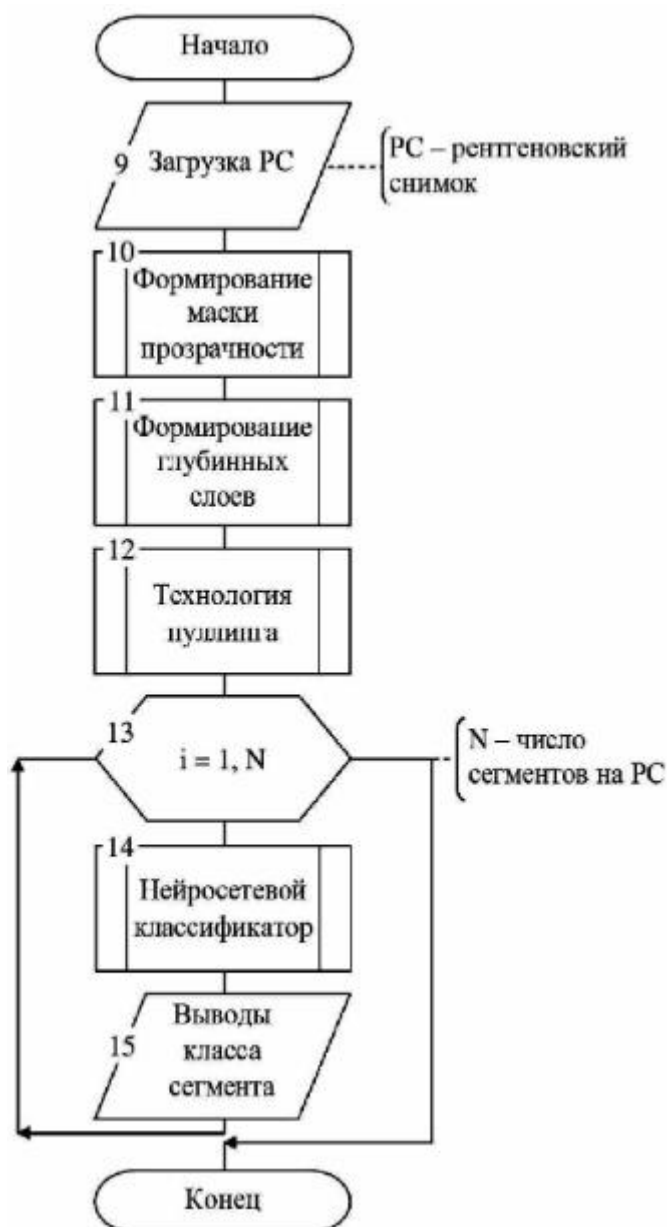


Рисунок 3 – Схема автоматической сегментации

Несмотря на подробное описание алгоритма, патент не представляет радикально новых подходов к автоматической сегментации изображений.

В патенте [9] представлен способ автоматизированного анализа цифровых флюорографических снимков. В нем рассказывается о новом подходе к обучению на данных разного качества, его суть заключается в том, что изображения делятся на три категории по качеству. Для каждой категории строится своя модель, что позволяет показать хорошее качество на сегментации. Однако на обучение и поддержание таких моделей в эксплуатации уйдет много ресурсов и времени для переобучения.

Общий вывод.

Наиболее перспективным, при условии недостаточного количества данных, является подход с обычной архитектурой U-Net т.к. она может показывать хорошее качество по техническим метрикам и позволяет использовать автоматическое переобучение. Также данная архитектура подходит для внедрения в виде веб-приложения в медицинских учреждениях. Можно отметить, что при обучении на небольшом количестве данных, нейронная сеть переобучается, но достигает хорошего качества. Были проанализированы методы обучения, которые используются для повышения качества и уменьшения переобучения нейронных сетей, а в частности U-Net. Представленные методы позволяют достичь лучшего качества на большом количестве данных.

Перспективным направлением является разработка метода обучения нейронной сети, который будет устранять переобучение при небольших данных для обучения.

### **1.3 Выбор направления исследования**

После анализа методов сегментации изображений был проанализирован сам процесс обучения и взаимодействие моделей с данными. В изученных источниках были представлены следующие виды обучения [10]:

1. Обучение с учителем (supervised learning) - это когда нейронная сеть обучается на основе размеченных данных, где каждый пример имеет метку или ответ. Сеть пытается предсказать правильный ответ для каждого примера, и корректируется в случае ошибки. supervised learning в задаче сегментации эхокардиографических изображений хорошо себя зарекомендовал в научных работах и прост в применении, но требует размеченных данных, что может не всегда быть в медицине [11].

2. Обучение с подкреплением (reinforcement learning) - это когда нейронная сеть обучается на основе взаимодействия со средой, где сеть получает вознаграждение или штраф в зависимости от своих действий. Сеть пытается максимизировать получаемое вознаграждение. Reinforcement learning может быть сложным и затратным в обучении, так как требует многократного взаимодействия с окружающей средой для получения достаточного количества данных. Кроме того, не всегда легко определить правильное вознаграждение или штраф для сети, что может привести к неправильному обучению и низкой точности модели [12].

3. Передача обучения (transfer learning) - это когда нейронная сеть обучается на основе предобученной модели, которая уже имеет некоторые знания и опыт в решении задачи. Это позволяет ускорить процесс обучения и улучшить точность модели. Transfer learning обычно дает хорошие результаты по метрикам, но не всегда контролируем т.к. в основе него лежит предобученная нейронная сеть с сохраненными весами, поэтому если модель начнет выдавать плохое качество, то придется либо брать другую предобученную модель, либо обучать другим способом [13].

В ходе изучения научных статей по U-Net было определено, что U-Net может показывать хорошее качество даже на небольших объемах данных (100-200 изображений) [14]. Поэтому был выбран первый подход, он более контролируемый и надежный.

При изучении представленных методов обучения нейронной сети с учителем выяснилось, что существует два подхода:

1. Классическое обучение на всех данных

Этот подход обеспечивает хорошее качество, но занимает продолжительное время и переобучает модель.

2. Обучение предобученной модели

Этот подход ускоряет обучение, но не показывает хорошего качества на не качественных изображениях

Решить проблему этих методов можно новым методом обучения, который поможет справиться с переобучением и не будет затратным для введения новых данных. Этот метод и станет направлением исследования работы.

## **2 ОБУЧЕНИЕ U-NET ДЛЯ СЕГМЕНТАЦИИ ЭХОКАРДИОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЙ**

### **2.1 Нейронная сеть U-Net**

U-Net - это нейронная сеть, разработанная в 2015 году для сегментации медицинских изображений. Она была создана офтальмологом Ольгером Роннебергом (Olaf Ronneberger) и его коллегами из университета Фрайбурга в Германии [15].

U-Net получила свое название благодаря своей архитектуре, которая напоминает букву "U". Сеть состоит из энкодера, который сжимает изображение и извлекает его признаки, и декодера, который восстанавливает изображение из сжатого представления. Кроме того, U-Net имеет skip-connections, которые позволяют передавать информацию о признаках из энкодера в декодер [15].

U-Net была разработана для решения задачи сегментации медицинских изображений, таких как сегментация опухолей на МРТ или сегментация клеток на микроскопических изображениях. Однако ее архитектура была успешно применена и в других областях, связанных с обработкой изображений.

С тех пор U-Net стала одной из самых популярных архитектур для сегментации изображений и используется во многих научных и прикладных работах. Ее успех объясняется не только высокой точностью, но и относительной простотой в реализации и обучении [16].

Архитектура U-Net состоит из энкодера, декодера и связующего слоя.

Энкодер состоит из сверточных слоев, которые понижают размерность изображения и извлекают признаки. Каждый сверточный слой содержит несколько фильтров, которые сканируют изображение и

выделяют определенные признаки. После каждого сверточного слоя применяется функция активации, например, ReLU.

После энкодера следует связующий слой, который соединяет энкодер и декодер. Этот слой содержит сверточные слои, которые сохраняют информацию о признаках из энкодера.

Декодер состоит из транспонированных сверточных слоев, которые увеличивают размерность изображения и восстанавливают его форму. Каждый транспонированный сверточный слой содержит несколько фильтров, которые сканируют изображение и выделяют определенные признаки. После каждого транспонированного сверточного слоя применяется функция активации [17].

В процессе декодирования используются связи между слоями, которые позволяют передавать информацию о признаках из энкодера в декодер. Это позволяет улучшить качество сегментации [18].

В конце декодера применяется слой с функцией активации Softmax, который преобразует выходные данные в вероятности для каждого пикселя изображения. Эти вероятности используются для сегментации изображения на классы.

# Network Architecture




Рисунок 4 – Архитектура нейронной сети U-Net

Существует несколько видов архитектур U-Net, которые отличаются количеством слоев и параметров [19]:

1. Оригинальная архитектура U-Net, которая состоит из энкодера, декодера и связующего слоя.
2. U-Net++ - модификация оригинальной архитектуры, которая добавляет дополнительные связи между слоями и улучшает качество сегментации.
3. Attention U-Net - архитектура, которая использует механизм внимания для улучшения качества сегментации.
4. Residual U-Net - модификация U-Net с использованием блоков ResNet для улучшения производительности и точности.
5. Recurrent U-Net - архитектура, которая использует рекуррентные связи для улучшения качества сегментации.

6. Dense U-Net - архитектура, которая использует блоки DenseNet для улучшения производительности и точности.

U-Net используется в медицине для сегментации изображений, таких как эхокардиографические изображения, магнитно-резонансные изображения и компьютерные томографии. С помощью U-Net можно автоматически выделять границы различных органов и тканей на изображении, что позволяет получать точные измерения и диагностировать заболевания.

Например, U-Net используется для сегментации мозга на магнитно-резонансных изображениях, что позволяет определить размеры различных областей мозга и выявить заболевания, такие как опухоли и инсульты [20]. Также U-Net применяется для сегментации легких на компьютерных томографиях, что помогает выявлять заболевания легких, такие как рак и пневмония.

U-Net может быть также использован для автоматической диагностики заболеваний сердца на эхокардиографических изображениях. Например, U-Net может определять размеры камер сердца и выявлять нарушения в работе клапанов. Это позволяет быстро и точно диагностировать заболевания сердца и назначить необходимое лечение [21].

## **2.2 Подбор инструментов разработки**

### **2.2.1 Выбор библиотеки для обучения нейронной сети**

Перед обучением нейронной сети нужно определиться с библиотекой. Существуют две популярные библиотеки для глубокого обучения: Pytorch и Tensorflow.

PyTorch - это библиотека для машинного обучения и глубокого обучения, разработанная компанией Facebook. Она предоставляет набор инструментов и функций для создания и обучения нейронных сетей, а также для работы с данными и моделями [22]. PyTorch использует

динамический вычислительный граф, что позволяет более гибко и быстро менять структуру модели в процессе обучения. Она также имеет лучшую поддержку для работы с GPU, что позволяет обучать модели на больших объемах данных

TensorFlow - это библиотека для машинного обучения и глубокого обучения, разработанная компанией Google. Она предоставляет набор инструментов и функций для создания и обучения нейронных сетей, а также для работы с данными и моделями [23]. TensorFlow использует статический вычислительный граф, что означает, что структура модели должна быть определена заранее и не может быть изменена в процессе обучения. TensorFlow также имеет хорошую поддержку для работы с GPU и TPU, что позволяет быстро и эффективно обучать модели на больших объемах данных. TensorFlow также имеет большое сообщество разработчиков, которые создают и делятся новыми библиотеками и инструментами для машинного обучения.

Преимущества PyTorch перед Tensorflow [24]:

1. Простота и удобство использования - PyTorch имеет более простой и интуитивно понятный интерфейс, что делает его более доступным для новичков в машинном обучении.

2. Динамический вычислительный граф - PyTorch использует динамический вычислительный граф, который позволяет более гибко и быстро менять структуру модели в процессе обучения.

3. Лучшая поддержка для работы с GPU - PyTorch имеет лучшую поддержку для работы с GPU, что позволяет обучать модели на больших объемах данных.

4. Большое сообщество разработчиков - PyTorch имеет большое сообщество разработчиков, которые активно создают и делятся новыми библиотеками и инструментами для машинного обучения.

5. Отладка - PyTorch позволяет более эффективно отлаживать модели благодаря своей динамической природе.

## 2.2.2 Выбор платформы для обучения модели

Google Colab (или Google Colaboratory) - это бесплатный сервис от Google, который позволяет запускать и использовать Jupyter Notebook в облаке [25]. Этот сервис позволяет пользователям создавать и запускать Python-код в браузере, используя бесплатные вычислительные ресурсы Google. Google Colab также предоставляет доступ к мощным GPU и TPU для обучения глубоких нейронных сетей и других задач машинного обучения.

Плюсы Google Colab:

- Бесплатный сервис с доступом к мощным вычислительным ресурсам.
- Возможность использовать Jupyter Notebook в облаке.
- Встроенная поддержка библиотек и фреймворков для машинного обучения, таких как TensorFlow, Keras, PyTorch и других.
- Поддержка GPU и TPU для обучения глубоких нейронных сетей.
- Возможность совместной работы и обмена данными с другими пользователями.

Минусы Google Colab:

- Ограниченное время выполнения для каждой сессии (12 часов) и ограниченный объем доступной оперативной памяти (около 12 ГБ).
- Не всегда стабильная работа сервиса из-за большой загрузки серверов.
- Ограниченный доступ к файловой системе и невозможность установки некоторых пакетов и библиотек.

Kaggle - это платформа для соревнований по машинному обучению, на которой участники могут решать различные задачи, используя данные и алгоритмы машинного обучения [26]. Она предоставляет доступ к большому количеству данных и инструментов для работы с ними, а также позволяет учиться на примере решения задач других участников.

Kaggle можно использовать для работы с изображениями, так как на платформе проводятся соревнования по классификации, сегментации и другим задачам обработки изображений. Участники могут использовать различные архитектуры нейронных сетей, в том числе U-Net, для решения этих задач. Кроме того, на Kaggle можно найти большое количество обучающих материалов и решений задач, которые помогут улучшить навыки работы с изображениями и машинным обучением в целом.

Kaggle предоставляет доступ к мощным графическим процессорам (GPU) для ускорения обучения моделей машинного обучения. Участники могут использовать GPU для обработки больших объемов данных и ускорения обучения нейронных сетей. Для использования GPU на Kaggle необходимо выбрать подходящее ядро (kernel) и настроить его на использование GPU. Кроме того, Kaggle предоставляет возможность использовать специализированные библиотеки для работы с GPU, такие как TensorFlow и PyTorch.

Преимущества Kaggle:

1. Удобный интерфейс и воспроизводимость своих экспериментов
2. Возможность использовать вычислительные ресурсы из виртуальных машин

Недостатки Kaggle:

1. Ограниченность времени вычислительных ресурсов - для решения некоторых задач может потребоваться большое количество времени, но GPU доступно только на 30 часов в неделю.

Опытным путем было проведено исследование, в ходе которого было выяснено, что обучение U-Net на платформе Kaggle в 5 раз быстрее. Поэтому для работы была выбрана платформа Kaggle.

## **2.2 Анализ данных для обучения**

Для обучения был взят датасет CAMUS (Cardiac Acquisitions for Multi-structure Ultrasound Segmentation) - это набор данных, содержащий

множество изображений сердца, полученных с помощью ультразвуковой томографии [27] Набор данных SAMUS был создан для разработки и тестирования алгоритмов автоматического сегментирования сердца на изображениях ультразвуковой томографии. Он состоит из двумерных срезов сердца, полученных от 450 пациентов. Каждый срез содержит информацию о четырех камерах сердца: левом желудочке, правом желудочке, левом предсердии и правом предсердии. Соответственно всего в датасете 1800 изображений. Но для обучения и предсказания используются только информация о левых желудочках.

Также из датасета можно получить информацию о качестве изображения и размерности.

patient	heart_state	view	quality	img_shape	img_name	msk_name
patient0217	ED	4CH	Medium	(630, 1038)	patient0217_4CH_ED.mhd	patient0217_4CH_ED_gt.mhd
patient0029	ES	4CH	Poor	(748, 1232)	patient0029_4CH_ES.mhd	patient0029_4CH_ES_gt.mhd
patient0317	ED	2CH	Good	(630, 1038)	patient0317_2CH_ED.mhd	patient0317_2CH_ED_gt.mhd
patient0438	ED	2CH	Medium	(472, 779)	patient0438_2CH_ED.mhd	patient0438_2CH_ED_gt.mhd
patient0107	ES	2CH	Medium	(630, 1038)	patient0107_2CH_ES.mhd	patient0107_2CH_ES_gt.mhd
...	...	...	...	...	...	...
patient0102	ED	4CH	Good	(669, 1102)	patient0102_4CH_ED.mhd	patient0102_4CH_ED_gt.mhd
patient0354	ED	4CH	Good	(433, 714)	patient0354_4CH_ED.mhd	patient0354_4CH_ED_gt.mhd
patient0036	ES	4CH	Medium	(787, 1297)	patient0036_4CH_ES.mhd	patient0036_4CH_ES_gt.mhd
patient0317	ES	2CH	Good	(630, 1038)	patient0317_2CH_ES.mhd	patient0317_2CH_ES_gt.mhd
patient0156	ES	4CH	Medium	(748, 1232)	patient0156_4CH_ES.mhd	patient0156_4CH_ES_gt.mhd

Рисунок 5 – Датасет с информацией об эхокардиографических изображениях пациентов

На рисунке 5 показан датасет с номером пациента. Состояние сердца(heart\_state) делится на два типа:

End-systolic - это фаза сердечного цикла, которая происходит в конце систолы, когда сердце сокращается и выталкивает кровь из желудочков в артерии. В этот момент давление в желудочках наибольшее, а объем крови в них наименьший [28].

End-diastolic - это фаза сердечного цикла, которая происходит в конце диастолы, когда желудочки наполняются кровью и достигают максимального объема. В этот момент давление в желудочках наименьшее, а объем крови в них наибольший [28].

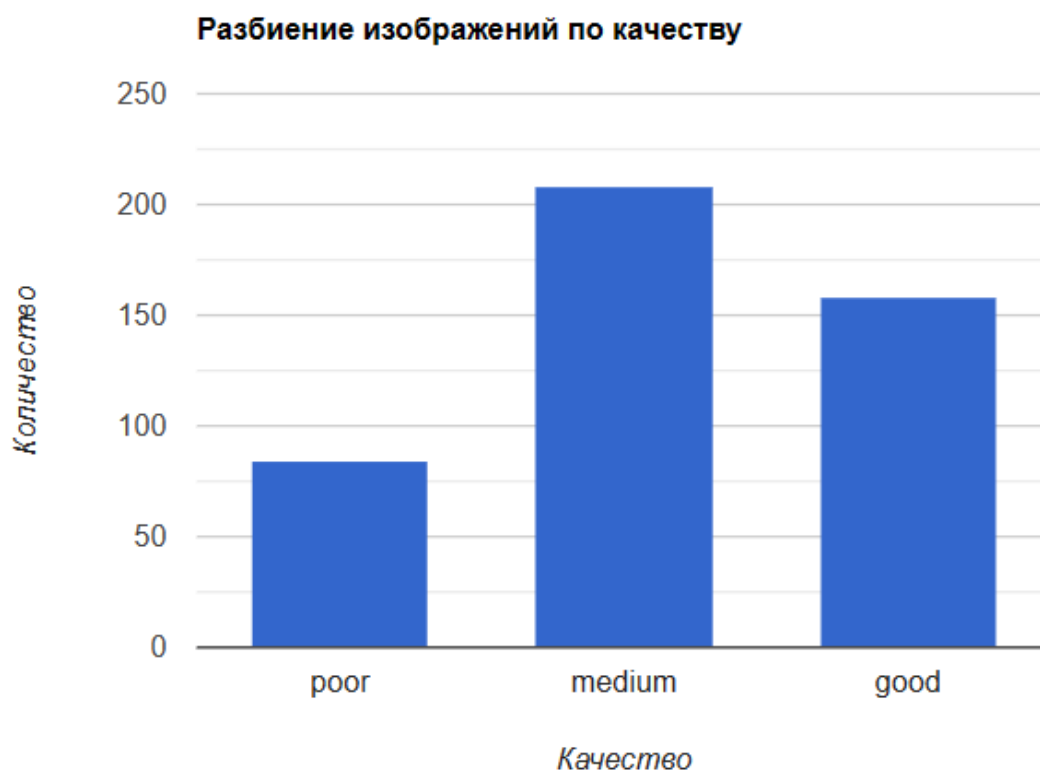


Рисунок 6 – График разбиения изображений в датасете по качеству

В датасете преобладает качество medium, изображения встречаются 208 раз. Good встречается 158 раз. Изображения с плохим качеством встречается 84 раза. Также есть информация об ejection fraction.

Ejection fraction (EF) - это процентное отношение объема крови, который выбрасывается из левого желудочка сердца во время систолы, к общему объему крови в левом желудочке. Нормальное значение EF составляет около 55-70%. Этот показатель является важным для оценки функции сердца и может быть использован для диагностики и контроля лечения различных заболеваний сердца, таких как сердечная недостаточность или инфаркт миокарда [29].




Рисунок 7 – Распределение ejection fraction

На графике представлено распределение EF, из которого видно, что 95 процентов значений EF распределено между 20 и 80. А нормальное значение должно находиться в пределах 55-70 процентов. Из этого следует, что данная выборка смещена.




Рисунок 8 – Пример маски левого желудочка

На рисунке 8 представлена маска для оконтуривания левого желудочка. Маска - это изображение, которое используется для выделения определенных областей или объектов на другом изображении. Маска может быть двоичной (бинарной), где каждый пиксель может быть либо черным (0) либо белым (1), или многоканальной, где каждый пиксель может иметь несколько значений, обозначающих различные свойства объекта, такие как цвет или текстура [28]. Маски часто используются в задачах компьютерного зрения, таких как распознавание объектов, сегментация изображений и удаление фона.




Рисунок 7 – Пример эхокардиографического изображения

На рисунке 7 изображены два эхокардиографических снимка разных пациентов, по ним модель пытается оконтурить желудочек и выдать изображение максимально похожее на маску из рисунка 6.




Рисунок 9 – Пример предсказания модели

На рисунке 9 изображены маска, эхокардиографический снимок и маска, предсказанная моделью. В данном примере модель хорошо оконтурит желудочек и показала точность в 0.956 по метрике dice. Таким образом будут предсказаны все клиенты в тестовой выборке.

## 2.4 Архитектура U-Net

### 2.4.1 Конволюционные нейронные сети

Свертка (Convolution) - это математическая операция, которая применяется в машинном обучении для обработки изображений и других типов данных. Она заключается в перемещении фильтра (ядра свертки) по

всей области входных данных и вычислении скалярного произведения между фильтром и соответствующей областью входных данных. Результатом операции свертки является новая матрица, которая содержит информацию о тех признаках изображения, которые были выделены фильтром [29]. Свертка используется в конволюционных нейронных сетях для выделения признаков изображения перед их классификацией.

Конволюционные нейронные сети (Convolutional Neural Networks, CNN) - это класс нейронных сетей, которые используются для обработки и анализа изображений, видео и звука. Они имеют специальную архитектуру, которая позволяет эффективно обрабатывать большие объемы данных [30].

Основной элемент конволюционной нейронной сети - это сверточный слой (Convolutional Layer), который применяет операцию свертки к входным данным.

Кроме сверточных слоев, в конволюционной нейронной сети могут использоваться такие слои, как слои пулинга (Pooling Layer), которые уменьшают размерность данных, и полносвязные слои (Fully Connected Layer), которые используются для классификации изображений.

Одной из особенностей конволюционных нейронных сетей является их способность к автоматическому извлечению признаков изображений. Это достигается путем обучения нейронной сети на большом количестве изображений, где каждое изображение имеет свой класс (например, кошка или собака). Нейронная сеть самостоятельно выделяет признаки, которые позволяют отличить один класс от другого [31].

Конволюционные нейронные сети находят широкое применение в различных областях, таких как компьютерное зрение, распознавание речи, обработка естественного языка и т.д. Они являются основой многих современных технологий, таких как автоматическое распознавание лиц, системы безопасности и автоматическое управление транспортом.

## 2.4.2 Максимальное объединение

Максимальное объединение (Max pooling) - это операция в машинном обучении, которая используется для уменьшения размерности изображений и других типов данных. Она заключается в разбиении входных данных на непересекающиеся блоки и выборе максимального значения из каждого блока. Результатом операции max pooling является новая матрица, которая содержит информацию о наиболее значимых признаках изображения [32].

Максимальное объединение используется в конволюционных нейронных сетях после операции свертки для уменьшения размерности данных и улучшения вычислительной эффективности. Она также помогает снизить эффект переобучения, удаляя ненужные признаки изображения.

Необходимо использовать максимальное объединение в тех случаях, когда размер изображения очень велик, чтобы уменьшить его размер. При максимальном объединении сохраняются только пиксели с максимальным значением. Эти значения на карте объектов показывают, насколько важен объект и его местоположение. Таким образом, использование только максимального значения означает извлечение наиболее важного признака в регионе[33].

Две причины для применения максимального объединения [34]:

1. Уменьшите масштаб изображения, выделив наиболее важную функцию
2. Устранение таких инвариантов, как сдвиг, вращение и масштабирование

Максимальное объединение выгодно, поскольку оно добавляет инвариантность к трансляции. Существуют следующие его виды [35]:

1. Неизменность сдвига (неизменность положения)
2. Вращательная инвариантность (неизменность во вращении)
3. Масштабная инвариантность (неизменность в масштабе (малом или большом))




Рисунок 10 – Схема максимального объединения

На рисунке 10 изображена схема работы максимального объединения [36]:

- 1) Окно 2x2 размечает изображение на части по 4 клетки.
- 2) Из каждого окна выбирается максимально значение.
- 3) В итоге получается сжатое в 4 раза изображение.

### 2.4.3 Пропускающие соединения

Пропускающие соединения(skip connections) - это техника в нейронных сетях, которая позволяет передавать информацию из более глубоких слоев нейронной сети в более поверхностные слои [37].

Пропускающие соединения часто используются в U-Net архитектуре, которая является сверточной нейронной сетью для сегментации изображений. В U-Net есть два основных пути: путь прямого прохода и путь обратного прохода. Путь прямого прохода состоит из сверточных слоев, которые уменьшают размерность изображения, и пулинг слоев, которые уменьшают размерность и усредняют значения признаков.

Путь обратного прохода состоит из транспонированных сверточных слоев, которые увеличивают размерность изображения, и пропускающих соединений, которые передают информацию из пути прямого прохода в путь обратного прохода. Это позволяет увеличить точность сегментации, так как информация о признаках из более глубоких слоев может быть использована для уточнения сегментации на более поверхностных слоях.

Пропускающие соединения также помогают предотвратить потерю информации о мелких деталях изображения, которые могут быть утеряны при уменьшении размерности изображения в пути прямого прохода. В целом, использование пропускающих соединений в U-Net позволяет получать более точные результаты сегментации изображений [37].

#### 2.4.4 Функция активации

Функция активации - это нелинейная функция, которая применяется к выходу нейрона. Она определяет, какой будет выход нейрона на основе входного сигнала [38]. Функция активации может быть различной в зависимости от типа нейронной сети и задачи, которую она решает.

Примеры функций активации [39]:

- Сигмоидальная функция:  $f(x) = 1 / (1 + \exp(-x))$ . Она используется для бинарной классификации, когда нужно получить вероятность принадлежности объекта к одному из двух классов.

- ReLU (Rectified Linear Unit):  $f(x) = \max(0, x)$ . Она используется для задач классификации и регрессии, где нужно предсказать числовое значение.

- Softmax:  $f(x) = \exp(x) / \sum(\exp(x))$ . Она используется для многоклассовой классификации, когда нужно определить вероятность принадлежности объекта к каждому из классов.

Функция активации позволяет нейронной сети обучаться и адаптироваться к новым данным. Она также помогает избежать проблемы

градиентного затухания, когда градиент становится слишком маленьким и не позволяет нейронной сети эффективно обучаться [40].

В U-Net используется ReLU (Rectified Linear Unit) как функция активации, потому что она показала хорошие результаты в задачах сегментации изображений. Она быстрее сходится и позволяет избежать проблемы градиентного затухания. Кроме того, она является простой и легко вычислимой функцией, что ускоряет процесс обучения нейронной сети [40].




Рисунок 11 – Функция активации RELU

На рисунке 11 представлено графическое изображение функции. Таким образом, функция активации ReLU просто возвращает входное значение, если оно положительное, и ноль, если оно отрицательное или равно нулю. Это делает ReLU очень простой и быстрой для вычисления, что является одним из ее преимуществ. Кроме того, ReLU имеет свойство разреживания (sparsity), что может быть полезным для регуляризации модели.

## 2.5 Метрики и интерпретация результатов сегментации

### 2.5.1 Dice

Dice метрика (или коэффициент Сёрнсена-Дайса) - это мера сходства между двумя наборами данных, которая часто используется для оценки качества сегментации изображений в задачах компьютерного зрения [41].

Формула Dice выглядит следующим образом [42]:

$$\text{Dice} = (2 * \text{TP}) / (2 * \text{TP} + \text{FP} + \text{FN}),$$

где TP (True Positive) - количество пикселей, которые были правильно отнесены к классу объекта, FP (False Positive) - количество пикселей, которые были ошибочно отнесены к классу объекта, FN (False Negative) - количество пикселей, которые были ошибочно отнесены к классу фона.

Dice метрика принимает значения от 0 до 1, где 1 означает идеальное совпадение двух наборов данных, а 0 - полное несовпадение. Чем ближе значение Dice метрики к 1, тем более точной считается сегментация объектов на изображении.

Dice метрика часто используется в задачах сегментации медицинских изображений, таких как сегментация опухолей или других аномалий. Она также может быть использована для оценки качества других задач компьютерного зрения, таких как детектирование объектов или классификация изображений [43].




Рисунок 12 – Значения квартилей по коэффициенту Dice для набора данных CAMUS

На рисунке 12 показан график значения Dice от количества точек, по которым интерполируется левый желудочек сердца. По нему можно понять, что оптимальное количество точек для интерполяции – 11.

## 2.5.2 Jaccard

Jaccard метрика (или коэффициент Жаккара) - это еще одна мера сходства между двумя наборами данных, которая часто используется для оценки качества сегментации изображений в задачах компьютерного зрения [44].

Формула Jaccard метрики выглядит следующим образом:

$$\text{Jaccard} = \text{TP} / (\text{TP} + \text{FP} + \text{FN}),$$

где TP (True Positive) - количество пикселей, которые были правильно отнесены к классу объекта, FP (False Positive) - количество пикселей, которые были ошибочно отнесены к классу объекта, FN (False Negative) - количество пикселей, которые были ошибочно отнесены к классу фона.

Jaccard метрика также принимает значения от 0 до 1, где 1 означает идеальное совпадение двух наборов данных, а 0 - полное несовпадение. Чем ближе значение Jaccard метрики к 1, тем более точной считается сегментация объектов на изображении.

Jaccard метрика также часто используется в задачах сегментации медицинских изображений, таких как сегментация опухолей или других аномалий. Она также может быть использована для оценки качества других задач компьютерного зрения, таких как детектирование объектов или классификация изображений [42].

Однако, в отличие от Dice метрики, Jaccard метрика более чувствительна к маленьким объектам на изображении и может давать более высокие значения при сегментации таких объектов.

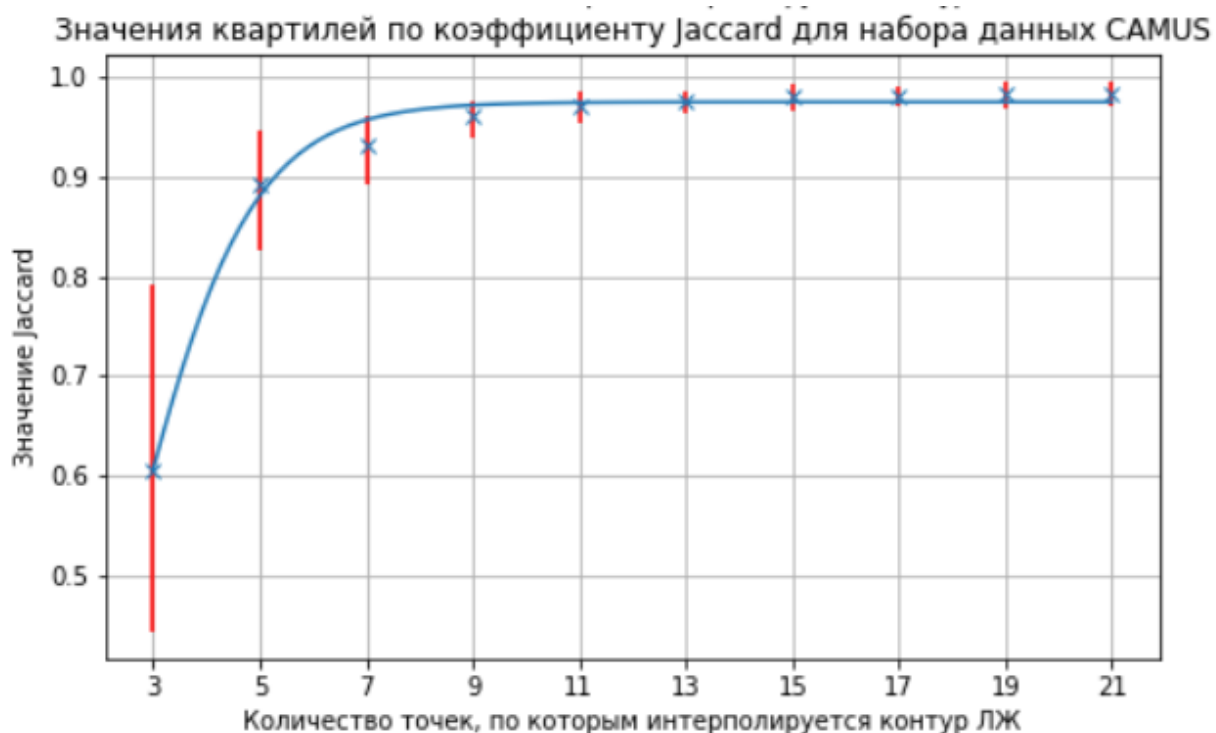


Рисунок 13 – Значения квантилей по коэффициенту Jaccard для набора данных CAMUS

На рисунке 13 показан график значения Jaccard от количества точек, по которым интерполируется левый желудочек сердца. По нему можно понять, что оптимальное количество точек для интерполяции также как и для Dice равно 11.

## 2.6 Интерпретация результатов работы модели

Существует несколько способов понять, хорошо ли модель работает.

1) Сравнение метрик на тренировочной выборке и тестовой позволяет оценить, насколько хорошо модель обобщается на новые данные. Если метрики на тренировочной выборке гораздо лучше, чем на тестовой, это может свидетельствовать о переобучении модели на тренировочных данных [45]. В таком случае, модель может работать очень хорошо на данных, которые она уже видела, но плохо справляться с новыми данными. Сравнение метрик на тренировочной и тестовой выборках помогает выбрать оптимальную модель, которая будет

работать на новых данных, а не только на тренировочных.

2) Если различие между трэйн и тест не велико, но значения метрик малы – это говорит о плохой способности модели к обобщению и говорит о плохой работе модели [46].

3) Также важна стабильность модели. Для проверки предсказания модели, можно воспользоваться кросс-валидацией. Кросс-валидация - это метод оценки качества модели, который позволяет использовать все данные для обучения и тестирования модели. Вместо того, чтобы разбивать данные на две части кросс-валидация разбивает данные на несколько частей (фолдов) и выполняет несколько циклов обучения и тестирования на разных комбинациях фолдов. Это позволяет получить более точную оценку качества модели и уменьшить вероятность переобучения [47].




Рисунок 14 – Схема кросс-валидации

На рисунке 14 показан пример схемы кросс-валидации. Данные делятся на пять частей, затем модель обучается на четырех частях, на пятой проверяет качество. Потом фолд проверки меняется и модель обучается на

других частях. И так пять раз. Если результат метрики примерно одинаковый, то это говорит о том, что модель стабильна.

## 2.7 Обучение U-Net

Алгоритм обучения U-Net включает следующие шаги:

1. Подготовка данных: подготовить данные для обучения и тестирования модели, включая разбиение данных на фолды для кросс-валидации.

fold 0			fold 1			fold 2			fold 3			fold 4		
quality			quality			quality			quality			quality		
medium	poor	good	medium	poor	good	medium	poor	good	medium	poor	good	medium	poor	good
22	10	18	22	10	18	22	10	18	24	9	17	24	8	18
fold 5			fold 6			fold 7			fold 8			fold 8		
quality			quality			quality			quality			quality		
medium	poor	good	medium	poor	good	medium	poor	good	medium	poor	good	medium	poor	good
24	9	18	23	9	18	22	10	18	24	10	16	22	10	18

Рисунок 15 – Таблица распределения изображений по фолдам

Фолды для проверки распределены равномерно по качеству изображения в каждом. Примерно так: среднее качество – 44%, плохое – 20%, хорошее – 36%.

2. Определение архитектуры U-Net: определить архитектуру U-Net, включая количество сверточных и декодерных слоев, размер фильтров и количество фильтров в каждом слое.

Архитектура выглядит так:

- Сверточный слой 3x3;
- Сверточный слой 3x3;
- MaxPooling 2x2;
- Сверточный слой 3x3;
- Сверточный слой 3x3;
- MaxPooling 2x2;
- Сверточный слой 3x3;
- Сверточный слой 3x3;

- MaxPooling 2x2;
- Сверточный слой 3x3;
- Сверточный слой 3x3;
- UpSampling 2x2;
- Сверточный слой 3x3;
- Сверточный слой 3x3;
- UpSampling 2x2;
- Сверточный слой 3x3;
- Сверточный слой 3x3;
- UpSampling 2x2;
- Сверточный слой 1x1.

UpSampling - это операция, которая увеличивает размерность изображения без потери информации. Она выполняется путем повторения каждого пикселя входного изображения несколько раз и заполнения промежутков между ними интерполяцией [48].

В U-Net используется UpSampling размерности 2x2, который удваивает размерность изображения в каждом измерении. Например, если входное изображение имеет размерность 256x256, то после первого MaxPooling его размерность уменьшится до 128x128, а после первого UpSampling - вернется к размерности 256x256 [49].

UpSampling выполняется в декодере U-Net на уровнях 12, 15 и 18 для постепенного увеличения размерности выходного изображения и восстановления его деталей. Каждый UpSampling слой соединен с соответствующим сверточным слоем на более низком уровне с помощью skip-connections, чтобы передать информацию о контексте и помочь декодеру восстановить более точные детали [48].

3. Обучение модели: обучить модель на тренировочных данных, используя оптимизатор и функцию потерь.

Для обучения используется оператор SGD. Он реализует стохастический градиентный спуск с моментумом. SGD - это метод оптимизации, который используется для обновления параметров модели на каждой итерации обучения [42]. Моментум - это метод, который учитывает предыдущие изменения параметров при обновлении весов модели. Это позволяет ускорить процесс обучения и сделать его более стабильным [50].

```
optimizer = torch.optim.SGD([
    {'params': model.parameters(), 'lr': 1e-4, 'momentum' : 0.99},
])
```

Рисунок 16 – Код оптимайзера SGD

В данном случае, оптимизатор применяется к параметрам модели, используя скорость обучения (lr) в размере 1e-4 и моментум в размере 0.99. Эти параметры могут быть изменены для достижения лучшего результата в обучении модели.

Для настройки процесса обучения используется шедулер. Шедулер в PyTorch - это объект, который позволяет динамически изменять параметры оптимизатора в процессе обучения модели [51].

```
scheduler = torch.optim.lr_scheduler.StepLR(optimizer, step_size=100, gamma=0.1)
```

Рисунок 17 – Код шедулера

Этот код создает объект класса StepLR из модуля torch.optim.lr\_scheduler, который будет уменьшать скорость обучения на заданный коэффициент (gamma) каждые step\_size эпох. Этот объект применяется к оптимизатору optimizer, который определяет, какие параметры модели будут обновляться в процессе обучения.

Например, если скорость обучения начинается с 0.1, то после первых 100 эпох она будет уменьшена до 0.01, после следующих 100 эпох - до 0.001 и т.д.

1. Оценка качества модели: оценить качество модели на тестовых данных, используя метрики, такие как loss, dice и jaccard.

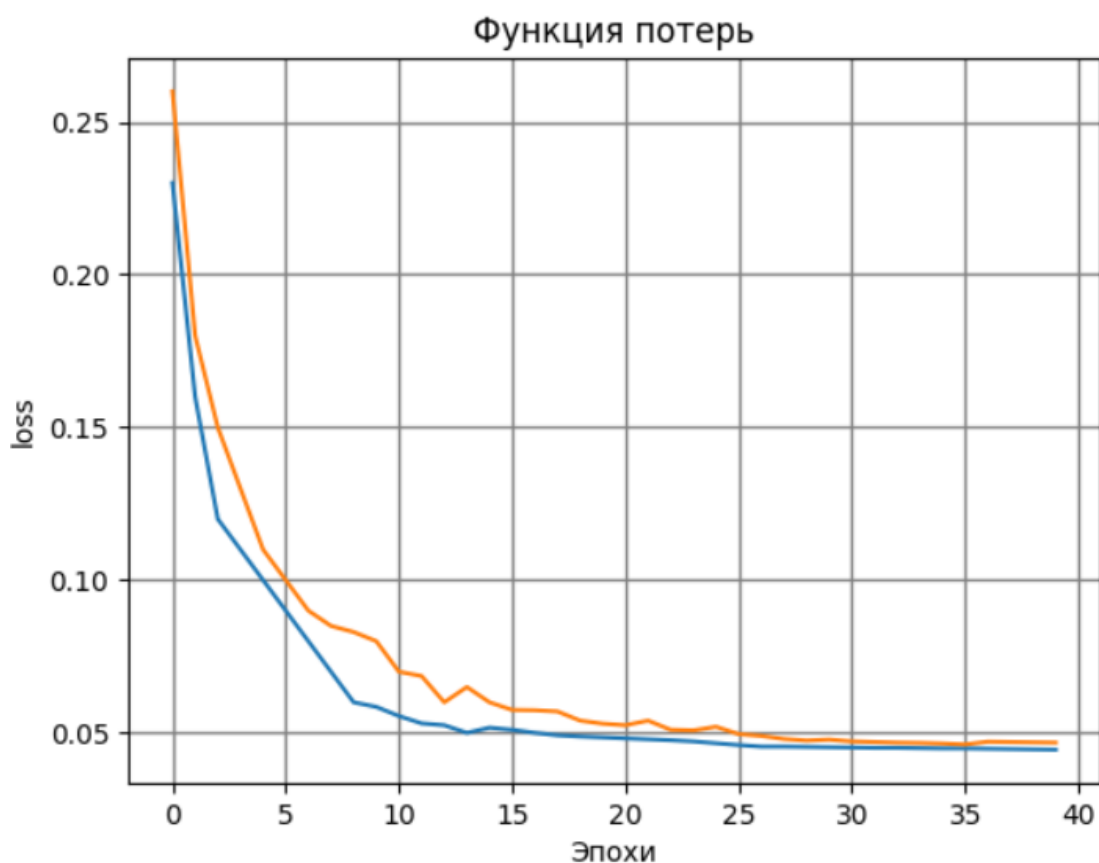


Рисунок 18 – График функции потерь

На рисунке 18 показан график функции потерь для обучающей выборки, которая выделена оранжевым цветом, и тестовой, выделена синим соответственно. Видно, что нейронная сеть сходится ближе к 27 эпохе.

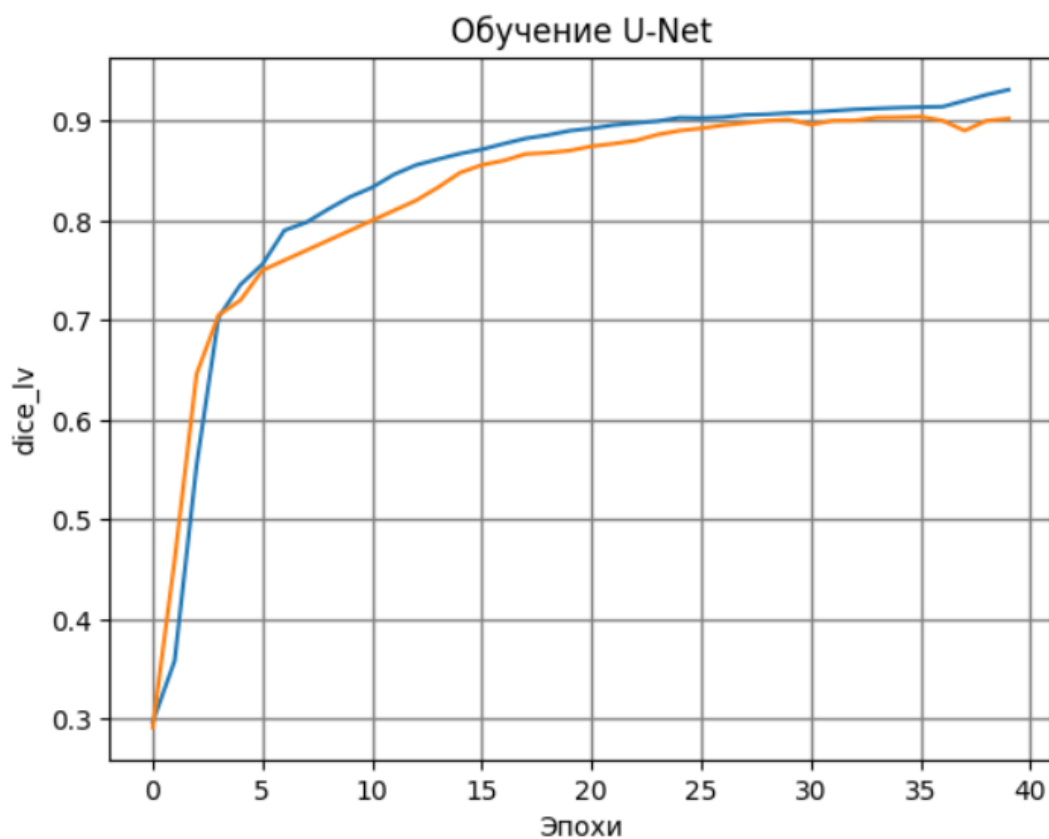


Рисунок 19 – График обучения U-Net

На рисунке 19 показан график обучения для обучающей выборки, которая выделена оранжевым цветом, и тестовой, выделена синим соответственно.

На графике видно, что оптимальное значение эпохи – 36, т.к. метрика  $dice$  в этот момент между обучающей и тестовой выборкой минимальна.

## 2.8 Обучение U-Net-fold

На рисунке 19 представлена схема этого способа, она заключается в изначальном разбиении датасета CAMUS на 10 частей, при этом равномерно распределив фолды по качеству изображений. Потом последовательно обучать U-Net на девяти фолдах на нескольких эпохах, потом сохранить текущие веса, обновить шедулер и продолжить обучение на других девяти фолдах.



Рисунок 20 – Схема обучения

Этот подход должен уменьшить переобучение в модели за счет постоянного добавления новых данных. Внутри него используется та же обычная архитектура U-Net.

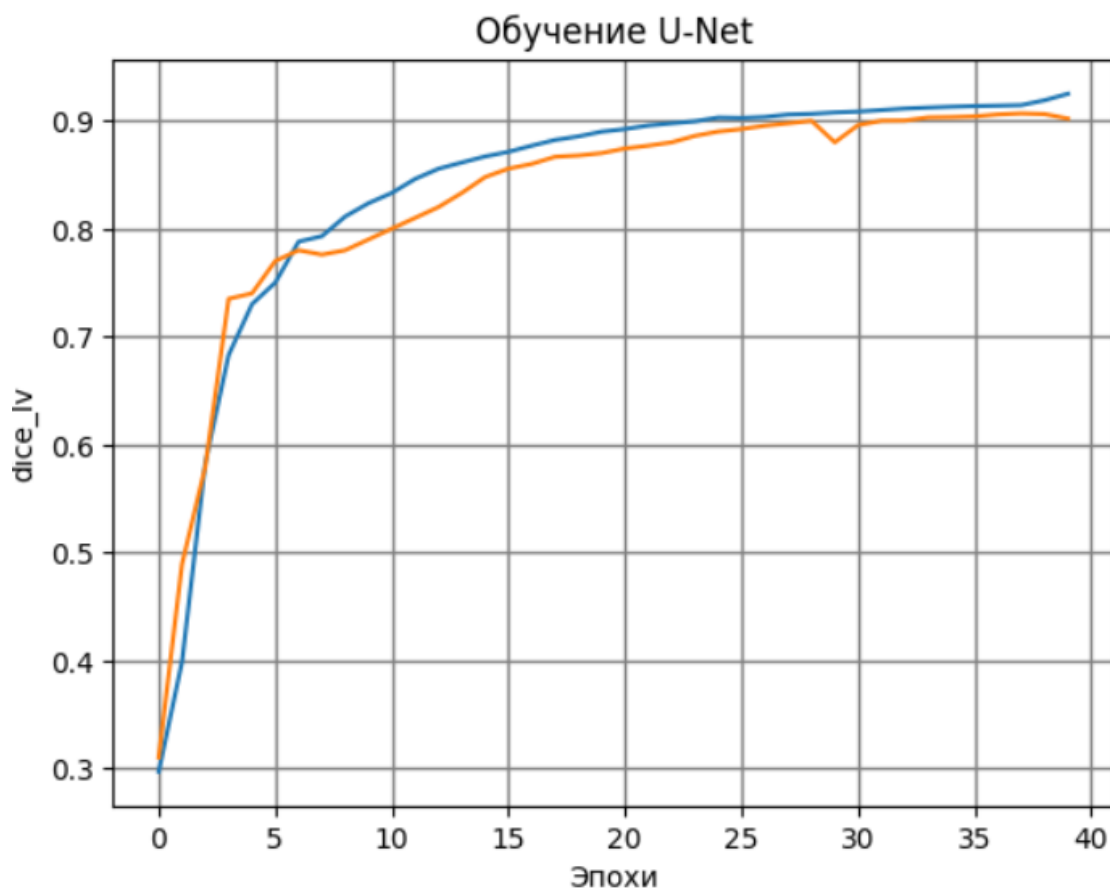


Рисунок 21 – Обучение U-Net fold

На рисунке 21 видно, что в этом варианте обучения разница между dice метрикой на тренировочной выборке и тестовой меньше, чем при обычном обучении U-Net. Это говорит о лучшей стабильности модели.




Рисунок 22 – График функции потерь U-Net fold

## 2.9 Итоговое сравнение метрик моделей

Таблица 1 – Метрики моделей

	U-Net		U-Net-fold	
	Jaccard	Dice	Jaccard	Dice
Тренировочная выборка	0.8526	0.9114	0.8452	0.9027
Тестовая выборка	0.8417	0.8952	0.8397	0.8960

Исходя из метрик U-Net, обученный классическим методом имеет jaccard и dice выше на тренировочной выборке, но dice на тестовой выборке имеет очень близкие значения и у U-Net-fold он немного выше. Также разница между метриками на тренировочной и тестовой выборках у модели U-Net-fold ниже, что является показателем стабильности и лучшей обобщающей способности модели. Таким образом метод обучения U-Net-fold приводит уменьшению переобучения модели, а значит к более точным

предсказаниям для новых пациентов, что приводит к повышению эффективности лечения и своевременному выявлению заболеваний сердца.

### 3 ПРИМЕНЕНИЕ МЕТОДА ОБУЧЕНИЯ ДЛЯ СЕГМЕНТАЦИИ ЭХОКАРДИОГРАФИЧЕСКИХ ИЗОБРАЖЕНИЙ

#### 3.1 Описание бизнес-процесса AS-IS и TO-BE

AS-IS (англ. "как есть") - это описание текущего состояния бизнес-процесса или системы, которая уже функционирует в организации [55]. AS-IS анализ позволяет выявить сильные и слабые стороны процесса, определить проблемные зоны и выработать рекомендации по его улучшению. В результате AS-IS анализа формируется общее понимание процесса и его основных характеристик.

Для построения модели AS-IS был изучен процесс работы кардиолога с пациентами в медицинском центре:

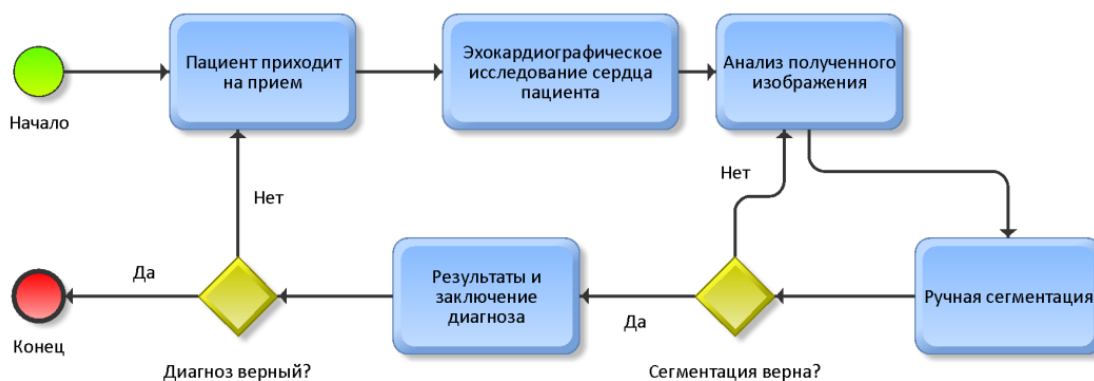


Рисунок 23 – Модель AS-IS

Вывод:

- Процесс ручной сегментации изображения характеризуется длительным временем процесса;
- Необходимо автоматизировать процесс сегментации изображений, чтобы ускорить прием пациентов и улучшить точность сегментации.

Из описания процесса AS-IS возникает гипотеза о возможной автоматизации процесса сегментации путем внедрения веб-приложения на основе нового метода обучения.

ТО-ВЕ (англ. "как должно быть") - это описание желаемого состояния бизнес-процесса или системы после внесения изменений и улучшений [56]. ТО-ВЕ анализ позволяет определить, каким должен быть процесс, чтобы достичь поставленных целей, улучшить эффективность и качество работы. В результате ТО-ВЕ анализа формируется новая модель процесса, которая может быть использована для разработки плана действий по его улучшению и реализации изменений в организации.

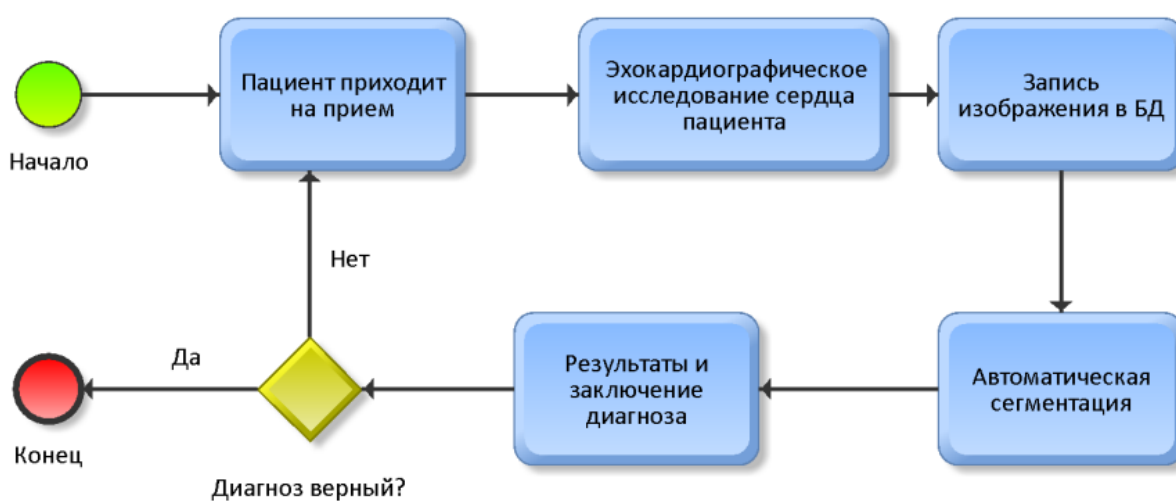


Рисунок 24 – Модель ТО-ВЕ

Плюсы внедрения модели ТО-ВЕ:

- Сокращение времени, затрачиваемого на сегментацию изображений врачами;
- Снижение затрат на обучение персонала для выполнения сегментации;
- Уменьшение количества ошибок при сегментации и, как следствие, снижение затрат на повторное проведение исследований;
- Увеличение количества пациентов, которые могут быть обследованы за определенный период времени благодаря ускорению процесса диагностики.

## 3.2 Разработка веб-приложения для эксплуатации

Алгоритм внедрения модели в веб-интерфейс приложения [52]:

1. Сбор данных: необходимо собрать достаточное количество эхокардиографических изображений левого желудочка с различными размерами и функциями. Эти данные должны быть размечены (аннотированы) для обучения модели.

2. Обучение модели: на основе собранных данных необходимо обучить модель машинного обучения для сегментации эхокардиографических изображений левого желудочка. Также у модели будет присутствовать возможность автоматического переобучения на новых данных.

3. Разработка веб-приложения: после обучения модели необходимо разработать веб-приложение, которое будет использовать эту модель для сегментации эхокардиографических изображений левого желудочка.

4. Тестирование и оптимизация: после разработки веб-приложения необходимо провести тестирование и оптимизацию модели и приложения для обеспечения быстрой и точной работы.

5. Развертывание: после тестирования и оптимизации приложение можно развернуть на сервере или облачной платформе, чтобы пользователи могли им пользоваться.

В приложении будут присутствовать следующие функции:

- Загрузка эхокардиографических изображений левого желудочка сердца ES и ED в формате .mhd;
- Просмотр загруженных изображений;
- Оконтуривание загруженных изображений;
- Выгрузка полученных результатов;
- Просмотр общей информации по пациенту;

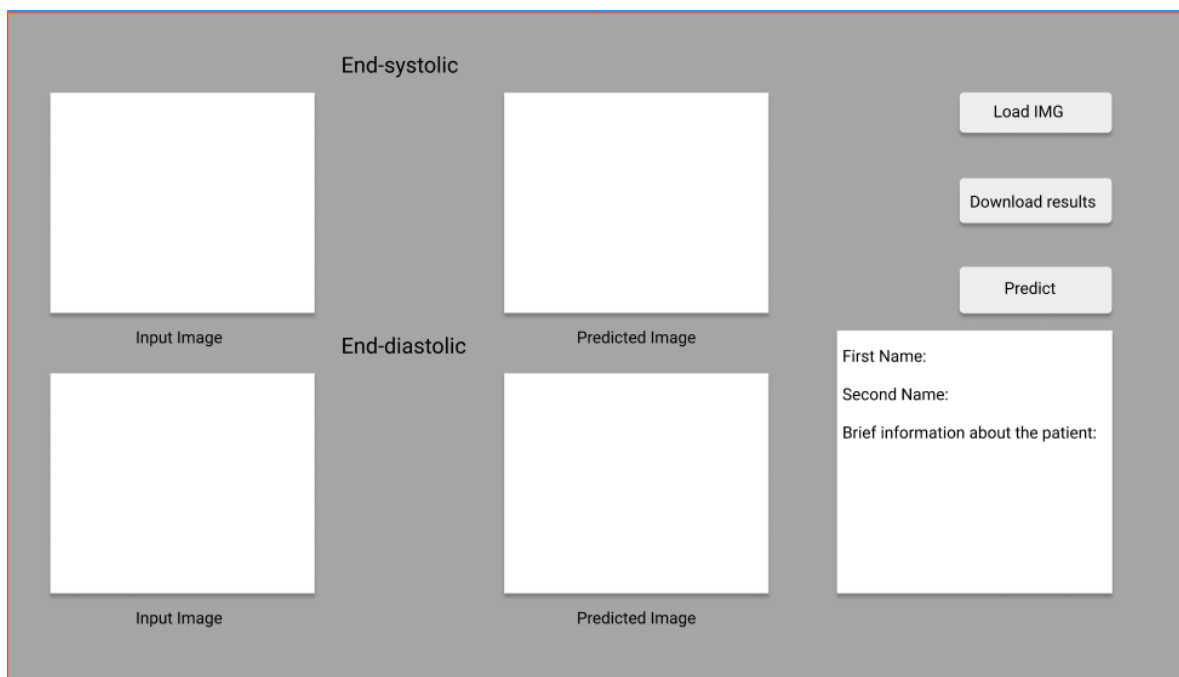


Рисунок 25 – Макет интерфейса приложения

На рисунках 25 и 26 изображен интерфейс приложения для оконтуривания левого желудочка сердца. Алгоритм работы с ним:

1) Нажать на кнопку “Load IMG” и загрузить с компьютера два эхокардиографических изображения желудочка в состоянии систолы и диастолы и файл с информацией о клиенте. Эти изображения и информация появятся в интерфейсе.

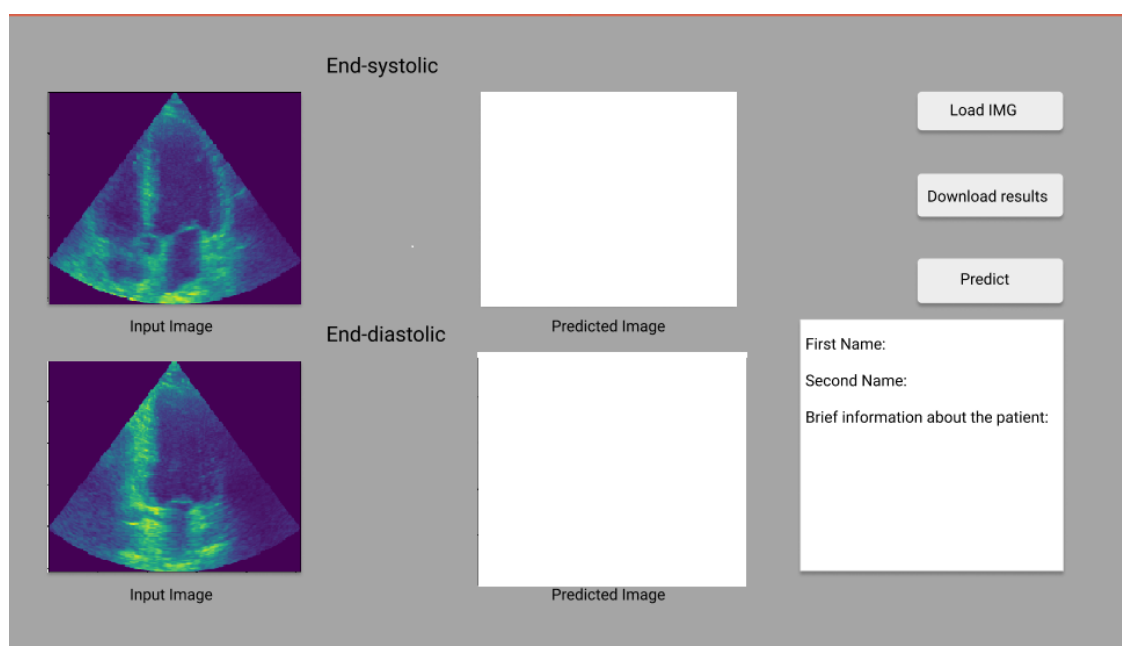


Рисунок 26 – Интерфейс до предсказания

2) Нажать на кнопку predict. В результате в интерфейсе появятся оконтуренные изображения левого желудочка в состояниях диастолы и систолы.

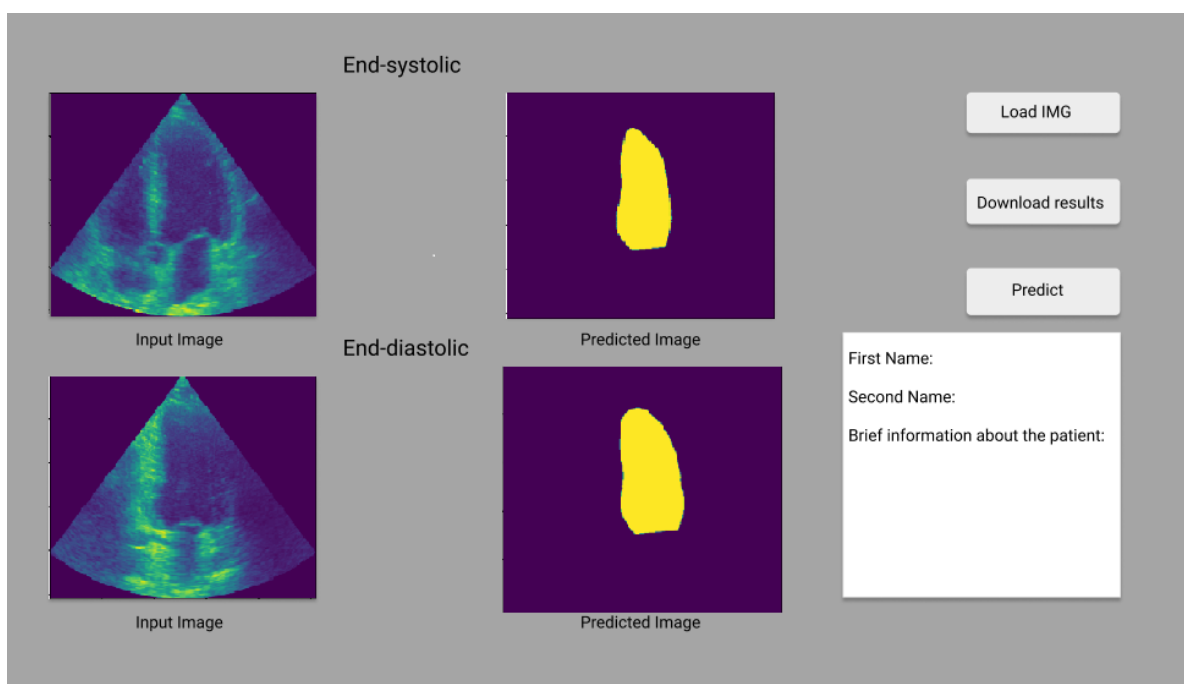


Рисунок 27 – Интерфейс после предсказания

3) После полученных результатов можно скачать результаты на персональный компьютер.

В результате моделирования был разработан веб интерфейс, позволяющий оконтурить эхокардиографические изображения левого желудочка сердца с точностью 90 процентов. Это приложение позволит ускорить и облегчить работу с пациентами, а хорошая точность улучшит качество диагноза заболеваний.

Интерфейс проекта будет разворачиваться в Docker. Docker - это инструмент для создания, управления и развертывания контейнеров. Он позволяет упаковывать приложения и их зависимости в изолированные контейнеры, которые могут быть запущены на любой платформе, где установлен Docker [53]. Это облегчает процесс разработки, тестирования и развертывания приложений, а также обеспечивает консистентность и надежность работы приложений в различных средах.

Алгоритм развертывания такого интерфейса выглядит так:

1. Подготовить модель машинного обучения, которую нужно развернуть в облаке.
2. Создать экземпляр виртуальной машины (Virtual Machine, VM) на платформе Docker. Это может быть виртуальная машина с GPU, если модель требует высокой производительности для обучения или инференса.
3. Установить необходимые зависимости и библиотеки на виртуальной машине.
4. Загрузить модель на виртуальную машину и настроить ее для запуска в продакшн-окружении.
5. Настроить сетевые правила и безопасность для доступа к API-интерфейсу модели. Например, можно использовать HTTPS для защиты передачи данных [54].
6. Протестировать работу модели в облаке и оптимизировать ее производительность при необходимости.
7. Развернуть модель в облаке и начать использовать ее для решения задач машинного обучения.

Для внедрения потребуется персональный компьютер, на котором будет подключен интернет и будет возможность загрузки электронной версии эхокардиографических изображений. Также необходимо заниматься мониторингом качества модели, потому что если качество будет падать, необходимо переобучить модель. Однако благодаря структуре U-Net, модель не требует много данных и ее можно переобучить меньше чем за день. Такой веб-интерфейс подойдет для любого медицинского учреждения, обладающего персональным компьютером и интернетом, и достаточно легко интегрируется в процесс работы, тем самым уменьшая нагрузку на врачей.

### **3.3 Описание проекта**

Цель проекта – разработать нейронную сеть позволяющую пользователю вносить данные и получать сегментированные изображения левого желудочка сердца.

Данная нейронная сеть позволит врачам быстрее и точнее обрабатывать эхокардиографические снимки. Что позволит увеличить количество

принимаемых пациентов и раньше обнаруживать заболевания сердца, тем самым принимать своевременные меры для их лечения.

Срок проекта: 45 рабочих дней к 10 июня 2023 года.

Команда проекта состоит из трех человек:

1) Руководитель: Медведев А.Н. Функции:

- Подготовка технического задания;
- Оказание исполнителю помощи в разработке подробного календарного графика выполнения работы и контроль его соблюдения;
- помощь исполнителю в поиске необходимых справочных материалов.

2) Разработчик: студент гр. РИМ-210981 Симахин Д.Е. Функции:

- Определение необходимого программного обеспечения;
- Моделирование
- Тестирование;
- Подготовка отчетной документации.
- 

### **3.4 Разработка проекта**

Планирование и разработка проекта является фундаментом для всей работы в целом. Заблаговременно продуманный план позволит сократить вероятность ошибок в дальнейшей работе, что может привести к нарушению сроков и качества выполнения проекта.

Для проектного управления применяются различные инструменты планирования. На начальном этапе разрабатывается дерево задач. Затем в диаграмме Ганта распределяются затраты по видам работ. И в конце строится сетевой график, который определяет последовательность работ и показывает критический путь.

### 3.4.1 Построение дерева задач

Дерево задач рассматривает последовательное разбиение общей цели проекта на подцели и задачи. Основная цель разбивается на множество связанных между собой событий, которые в дальнейшем выполняются участниками проекта. Дерево задач проекта представлено на рисунке 22.

Идентификатор	Название задачи	Дата начала	Дата окончания	Дни
1	<b>Разработка проекта</b>	20.04.2023	06.06.2023	48
2	<b>Постановка задачи</b>	20.04.2023	28.04.2023	9
3	Изучение материала по теме	20.04.2023	24.04.2023	5
4	Оценка целесообразности	25.04.2023	26.04.2023	2
5	Разработка ТЗ	27.04.2023	28.04.2023	2
6	<b>Моделирование</b>	29.04.2023	23.05.2023	25
7	Обучение U-Net	29.04.2023	13.05.2023	15
8	Обучение U-Net-fold	14.05.2023	23.05.2023	10
9	<b>Тестирование</b>	24.05.2023	28.05.2023	5
10	Проверка стабильности и качества модели	24.05.2023	28.05.2023	5
11	<b>Завершение проекта</b>	29.05.2023	06.06.2023	9
12	Оптимизация	29.05.2023	31.05.2023	3
13	Написание отчета	01.06.2023	05.06.2023	5
14	Сдача проекта	06.06.2023	06.06.2023	1

Рисунок 25 – Дерево задач проекта

### 3.4.2 Построение диаграммы Ганта

Диаграмма Ганта - один из наиболее популярных методов, используемых в управлении проектами. Диаграмма представляет собой отрезки, размещенные на горизонтальной шкале времени [57]. Каждый отрезок соответствует отдельной задаче или подзадаче. Диаграмма Ганта для проекта в рамках ВКР представлена на рисунке 26.




Рисунок 26 – Диаграмма Ганта

Диаграмма Ганта хорошо иллюстрирует, что должно быть сделано с течением времени, также показывает, как задачи зависят друг от друга - каждая задача не может начаться раньше окончания предыдущей задачи. В общей сложности проект выполняется за 48 дней.

### 3.4.3 Перечень работ по проекту

Сетевой график – графическое изображение определенного комплекса работ с учетом их длительности, взаимосвязи и технологической последовательности [58]. В таблице 1 указаны все события, а также их длительность и результат выполнения.

Таблица 2 – Перечень работ по проекту

№	Событие	Длительность, дни	Результат события
1	Постановка задачи	9	Список задач
1.1	Изучение материала по теме проекта	5	Теоретические знания
1.2	Оценка целесообразности	2	Принятие решения о целесообразности проекта
1.3	Разработка ТЗ	2	Техническое задание
2	Моделирование	25	Рабочие модели
2.1	Обучение U-Net	15	Обученная модель U-Net
2.2	Обучение U-Net-fold	10	Обученная модель U-Net-fold
3	Тестирование	5	Отлаженная модель
3.1	Проверка стабильности и качества модели	5	Проверка и отладка моделей
4	Завершение проекта	9	Готовый проект
4.1	Отладка и оптимизация	3	Оптимизация кода
4.2	Написание отчета	5	Отчет о проекте
4.3	Сдача проекта	1	Готовый проект

На основании таблицы можно сделать следующие выводы:

- Критический путь проекта составляет 48 дней;
- Наиболее продолжительный этап – моделирование, он составляет 25 дней;

- Все задачи идут последовательно, что значительно увеличивает время проекта.

Также были изучены риски проекта:

1. Сбой соединения с интернетом.

Существует вероятность, что соединение с интернетом может быть прервано по какой-то причине. Причины сбоя соединения с интернетом: выход из строя оборудования, не оплаченные услуги Интернет-провайдера.

2. Выход из строя ПК.

Персональный компьютер может выйти из строя по причине: неправильного использования, перебоя в напряжении, величины срока службы.

3. Перебои с электричеством.

Риск отключения электричества зависит от соблюдения правил пользования электрооборудованием.

4. Непредвиденное увеличение сроков проекта.

В момент написания проекта разработчик может заболеть

5. Внесение изменений в ТЗ.

Заказчик, в ходе работы над проектом, может потребовать внести изменения в готовый продукт.

6. Невыполнение планируемых объемов работ в запланированный срок.

Плохо спланированные этапы не позволяют закончить проект в срок.

7. Пожар или затопление.

Пожар или затопление на рабочем месте могут привести к потере большого объема данных необходимых для разработки или же вовсе к полному уничтожению компьютерной техники.

### **3.6 Экономическая эффективность проекта**

Для подсчета экономической эффективности использовались следующие показатели:

- Средняя стоимость приема кардиолога с УЗИ сердца 1000 руб

- Среднее время приема кардиолога – 24 минуты [60]
- Кардиолог работает в неделю 33 часа [61]
- Время, затрачиваемое на ручную сегментацию эхокардиографического изображения, может значительно варьироваться в зависимости от опыта и навыков оператора, сложности изображения и используемого программного обеспечения. В среднем, процесс ручной сегментации может занять от нескольких минут до получаса [62].

- Процесс автоматической сегментации – 11 минут
- Согласно данным American College of Cardiology, точность диагностики заболеваний сердца с помощью эхокардиографии составляет около 90% [63].

- Точность диагноза при автоматической сегментации – 90%

$$\text{Кол – во приемов при ручной сегментации} = \frac{33 * 60}{24} = 82 \quad (1)$$

$$\begin{aligned} \text{Кол – во приемов при автоматической сегментации} &= \frac{33 * 60}{24 - (15 - 11)} \\ &= 99 \quad (2) \end{aligned}$$

$$\begin{aligned} \text{Прибыль в месяц до внедрения} &= (82 * 1000 \text{руб.}) * 4 \\ &= 328 000 \text{руб.} \quad (3) \end{aligned}$$

$$\begin{aligned} \text{Прибыль в месяц после внедрения} &= (99 * 1000 \text{руб.}) * 4 \\ &= 396 000 \text{руб.} \quad (4) \end{aligned}$$

$$\text{Доп прибыль в месяц} = 396 000 - 328 000 = 68 000 \text{руб.} \quad (5)$$

Затраты на внедрение:

- Развертывание базы данных – 500 000 руб.
- Поддержка постоянного домена на год – 10 000 руб.
- Техническое обслуживание – 400 000 руб. в год
- Компьютер и сервер – 80 000 руб.

### Затраты на внедрение – 990 000 руб.




Рисунок 28 – График прибыли в зависимости от внедрения веб-приложения

На рисунке 28 видно, что прибыль после внедрения веб-приложения для автоматического сегментирования эхокардиографических изображений превышает текущую на 16-ый месяц. А через полтора года после внедрения, будет превышать уже на 320 тысяч рублей. Также качество сегментации останется на таком же уровне, что позволит ставить точные диагнозы. Это говорит о том, что проект является экономически эффективным.

## ЗАКЛЮЧЕНИЕ

В данной работе была рассмотрена тема "Сегментация эхокардиографического изображения с применением нейронных сетей". В работе был проведен анализ базы научных исследований, рассмотрены основные методы сегментации изображений, сердца, проведен анализ эффективности применяемых методов, вследствие которого было выбрано направление исследования.

Был разработан метод обучения U-Net-fold, который приводит уменьшению переобучения модели, а значит к более точным предсказаниям для новых пациентов, что приводит к повышению эффективности лечения и своевременному выявлению заболеваний сердца.

В результате моделирования был разработано веб-приложение, позволяющее оконтурить эхокардиографические изображения левого желудочка сердца с точностью 90 процентов. Это приложение позволит ускорить и облегчить работу с пациентами, а хорошая точность улучшит качество диагноза заболеваний.

В ходе проектного управления были разработаны: дерево задач, диаграмма Ганта и сетевой график, а также учтены риски проекта.

Дерево задач отражает структурированный перечень задач с их длительностью, датами начала и завершения работ.

Диаграмма Ганта показывает, как затраты распределяются по видам работ. По ней видно, что все задачи проекта выполняются последовательно и связаны между. Продолжительность проекта согласно диаграмме составляет 45 дней.

Сетевой график, показывает критический путь проекта, равный 45 дням, и отражает последовательность этапов проекта, что обеспечивает упорядоченность и согласованность действий участников проекта.

Было выявлено 7 рисков проекта. С учетом одновременного наступления всех рисков длительность проекта предположительно увеличится на 42 дня. Итоговая длительность будет равна 97 дням.

Была посчитана экономическая эффективность от внедрения проекта. Веб-приложение начинает приносить больше прибыли на 16-ый месяц эксплуатации. Через полтора года прибыль превышает текущую на 320 тыс. рублей.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Берштейн, Л. Л. Эхокардиография при ишемической болезни сердца / Л. Л. Берштейн. — 1-е изд. — Москва : ГЭОТАР-Медиа, 2016. — 96 с.
2. Крис, Элбон Машинное обучение с использованием Python. Сборник рецептов / Элбон Крис. — : БХВ, 2019. — 384 с.
3. Expertly curated abstract & citation database. — Текст : электронный // elsevier : [сайт]. — URL: <https://www.elsevier.com/solutions/scopus> (дата обращения: 11.06.2023).
4. Публикация в Scopus: быстро, бесплатно и с гарантией.. — Текст : электронный // научныепереводы : [сайт]. — URL: <https://xn--80aegsaabcbngm5abc1ci.xn--p1ai/scopus/?ysclid=lir5ybpnhd200901469> (дата обращения: 11.06.2023).
5. СПОСОБ ОБУЧЕНИЯ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ВОССТАНОВЛЕНИЯ ИЗОБРАЖЕНИЯ И СИСТЕМА ДЛЯ ФОРМИРОВАНИЯ КАРТЫ ГЛУБИНЫ ИЗОБРАЖЕНИЯ (ВАРИАНТЫ). — Текст : электронный // yandex : [сайт]. — URL: [https://yandex.ru/patents/doc/RU2698402C1\\_20190826](https://yandex.ru/patents/doc/RU2698402C1_20190826) (дата обращения: 11.06.2023).
6. Способ автоматической классификации рентгеновских изображений с использованием масок прозрачности. — Текст : электронный // yandex : [сайт]. — URL: [https://yandex.ru/patents/doc/RU2716914C1\\_20200317](https://yandex.ru/patents/doc/RU2716914C1_20200317) (дата обращения: 11.06.2023).
7. СПОСОБ АВТОМАТИЗИРОВАННОГО АНАЛИЗА ЦИФРОВЫХ ФЛЮОРОГРАФИЧЕСКИХ СНИМКОВ. — Текст : электронный // yandex : [сайт]. — URL: [https://yandex.ru/patents/doc/RU2684181C1\\_20190404](https://yandex.ru/patents/doc/RU2684181C1_20190404) (дата обращения: 11.06.2023).
8. Джереми, Уатт Машинное обучение: основы, алгоритмы и практика применения / Уатт Джереми. — : ВHV-СПб, 2022. — 640 с.

9. Бурков Андрей Машинное обучение без лишних слов. – Питер, 2020. – 81–89.
10. Гудфеллоу, Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль. — : АСТ, 2017. — 580 с.
11. Понимание семантической сегментации с помощью U-Net: [Электронный ресурс] –URL:  
<https://machinelearningmastery.ru/understanding-semantic-segmentation-with-unet-6be4f42d4b47/?ysclid=lia080vqpx656825258>
12. U-Net: Convolutional Networks for Biomedical Image Segmentation. — Текст : электронный // arxiv.org : [сайт]. — URL: <https://arxiv.org/pdf/1505.04597.pdf> (дата обращения: 30.05.2023)
13. Небольшое исследование свойств простой U-net, классической сверточной сети для сегментации. — Текст : электронный // habr.com : [сайт]. — URL: <https://habr.com/ru/companies/ods/articles/431512/> (дата обращения: 30.05.2023)
14. understanding-and-implementing-u-net-architecture. — Текст : электронный // medium.com : [сайт]. — URL: <https://ayushsojitra1.medium.com/understanding-and-implementing-u-net-architecture-622369538ced> (дата обращения: 30.05.2023)
15. U-Net architecture. — Текст : электронный // iq.opengenus.org : [сайт]. — URL: <https://iq.opengenus.org/u-net/> (дата обращения: 30.05.2023)
16. U-Net: нейросеть для сегментации изображений. — Текст : электронный // neurohive : [сайт]. — URL: <https://neurohive.io/ru/vidy-nejrosetej/u-net-image-segmentation/> (дата обращения: 30.05.2023).
17. U-Net Architecture For Image Segmentation. — Текст : электронный // paperspace : [сайт]. — URL: <https://blog.paperspace.com/unet-architecture-image-segmentation/> (дата обращения: 30.05.2023).
18. ПРИМЕНЕНИЕ НЕЙРОННОЙ СЕТИ АРХИТЕКТУРЫ U-Net ДЛЯ СЕГМЕНТАЦИИ СТМ-ИЗОБРАЖЕНИЙ. — Текст : электронный // cyberleninka : [сайт]. — URL: <https://cyberleninka.ru/article/n/primenenie->

- nei-ronnoi-seti-arhitektury-u-net-dlya-segmentatsii-stm-izobrazhenii?ysclid=liadc4txn616118754 (дата обращения: 30.05.2023).
19. Ховард, Джереми Глубокое обучение / Джереми Ховард, Сильвейн Гуггер. — Питер : , 2022. — 640 с.
20. Kaggle за 30 минут: практическое руководство для начинающих. — Текст : электронный // proglib : [сайт]. — URL: <https://proglib.io/p/kaggle-za-30-minut-prakticheskoe-rukovodstvo-dlya-nachinayushchih-2021-09-17?ysclid=liadtzfk76529281316> (дата обращения: 30.05.2023).
21. За кулисами Google Colab. — Текст : электронный // habr : [сайт]. — URL: <https://habr.com/ru/companies/skillfactory/articles/673572/> (дата обращения: 30.05.2023)
22. Как правильно "фармить" Kaggle. — Текст : электронный // habr : [сайт]. — URL: <https://habr.com/ru/companies/ods/articles/426227/> (дата обращения: 03.06.2023).
23. Воробьев, А. С. Амбулаторная эхокардиография у детей / А. С. Воробьев. — : СпецЛит, 2019. — 126 с
24. Новиков, В. И. Эхокардиография. Методика и количественная оценка / В. И. Новиков. — : МЕДпресс-информ, 2023. — 136 с.
25. Обрезана, А. Г. Кардиология. Новости. Мнения. Обучение. Журнал для непрерывного медицинского образования врачей 1/2021 / А. Г. Обрезана. — : ГЭОТАР-Медиа, 2021. — 96 с.
26. Введение в сверточные нейронные сети. — Текст : электронный // habr : [сайт]. — URL: <https://habr.com/ru/articles/454986/> (дата обращения: 03.06.2023).
27. Сверточные нейронные сети. — Текст : электронный // helenkaratsa : [сайт]. — URL: <https://www.helenkaratsa.ru/sviortochnaia-nieironnaia-siet/?ysclid=lifsmkjlyn520074630> (дата обращения: 03.06.2023).
28. Как работает сверточная нейронная сеть (CNN). — Текст : электронный // neurohive : [сайт]. — URL: <https://neurohive.io/ru/osnovy-data->

- science/glubokaya-svertochnaja-nejronnaja-set/ (дата обращения: 03.06.2023).
- 29.Convolutional Neural Networks, Explained. — Текст : электронный // towardsdatascience : [сайт]. — URL: <https://towardsdatascience.com/convolutional-neural-networks-explained-9cc5188c4939> (дата обращения: 03.06.2023).
- 30.Convolutional Neural Networks. — Текст : электронный // ibm : [сайт]. — URL: <https://www.ibm.com/topics/convolutional-neural-networks> (дата обращения: 03.06.2023).
- 31.Convolutional Neural Network definition. — Текст : электронный // deepai : [сайт]. — URL: <https://deepai.org/machine-learning-glossary-and-terms/convolutional-neural-network> (дата обращения: 03.06.2023).
- 32.Convolutional Neural Networks (CNNs / ConvNets). — Текст : электронный // cs231n : [сайт]. — URL: <https://cs231n.github.io/convolutional-networks/> (дата обращения: 03.06.2023).
- 33.Pooling In Convolutional Neural Networks. — Текст : электронный // paperspace : [сайт]. — URL: <https://blog.paperspace.com/pooling-in-convolutional-neural-networks/> (дата обращения: 03.06.2023).
- 34.Deep Learning: как это работает? Часть 2. — Текст : электронный // habr : [сайт]. — URL: <https://habr.com/ru/articles/510816/> (дата обращения: 03.06.2023).
- 35.Intuitive Explanation of Skip Connections in Deep Learning. — Текст : электронный // theaisummer : [сайт]. — URL: <https://theaisummer.com/skip-connections/> (дата обращения: 03.06.2023).
- 36.Выбор слоя активации в нейронных сетях: как правильно выбрать для вашей задачи. — Текст : электронный // habr : [сайт]. — URL: <https://habr.com/ru/articles/727506/> (дата обращения: 03.06.2023).
- 37.Activation Functions in Neural Networks. — Текст : электронный // towardsdatascience : [сайт]. — URL:

- <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6> (дата обращения: 03.06.2023).
38. Activation Functions in Neural Networks [12 Types & Use Cases]. — Текст : электронный // v7labs : [сайт]. — URL: <https://www.v7labs.com/blog/neural-networks-activation-functions> (дата обращения: 03.06.2023).
39. dice-ml - Diverse Counterfactual Explanations for ML Models. — Текст : электронный // coderzcolumn : [сайт]. — URL: <https://coderzcolumn.com/tutorials/machine-learning/dice-ml-diverse-counterfactual-explanations-for-ml-models> (дата обращения: 03.06.2023).
40. Understanding DICE COEFFICIENT. — Текст : электронный // kaggle : [сайт]. — URL: <https://www.kaggle.com/code/yerramvarun/understanding-dice-coefficient> (дата обращения: 03.06.2023).
41. Categorical Data, Jaccard's Coefficient, and Multiprocessing. — Текст : электронный // towardsdatascience : [сайт]. — URL: <https://towardsdatascience.com/categorical-data-jaccards-coefficient-and-multiprocessing-b4a7bd5d90f6> (дата обращения: 03.06.2023).
42. sklearn.metrics.jaccard\_score¶. — Текст : электронный // scikit-learn : [сайт]. — URL: [https://scikit-learn.org/stable/modules/generated/sklearn.metrics.jaccard\\_score.html](https://scikit-learn.org/stable/modules/generated/sklearn.metrics.jaccard_score.html) (дата обращения: 03.06.2023).
43. sklearn.metrics.cross\_validation¶. — Текст : электронный // scikit-learn : [сайт]. — URL: [https://scikit-learn.org/stable/modules/cross\\_validation.html](https://scikit-learn.org/stable/modules/cross_validation.html) (дата обращения: 03.06.2023).
44. Кросс-валидация (Cross Validation). — Текст : электронный // helenkaratsa : [сайт]. — URL: <https://www.helenkaratsa.ru/kross-validatsiia/?ysclid=liftqus6vg182330636> (дата обращения: 03.06.2023).
45. cross-validation-a-beginners-guide. — Текст : электронный // towardsdatascience : [сайт]. — URL: <https://towardsdatascience.com/cross-validation-a-beginners-guide-5b8ca04962cd> (дата обращения: 03.06.2023).

46. Downsampling and Upsampling in CNN. — Текст : электронный // opengenius : [сайт]. — URL: <https://iq.opengenus.org/downsampling-and-upsampling-in-cnn/> (дата обращения: 03.06.2023).
47. Here's what I've learnt about Sklearn.resample. — Текст : электронный // towardsdatascience : [сайт]. — URL: <https://towardsdatascience.com/heres-what-i-ve-learnt-about-sklearn-resample-ab735ae1abc4> (дата обращения: 03.06.2023).
48. Upsampling and Downsampling Imbalanced Data in Python. — Текст : электронный // wellsr : [сайт]. — URL: <https://wellsr.com/python/upsampling-and-downsampling-imbalanced-data-in-python/> (дата обращения: 03.06.2023).
49. Обзор методов супер-разрешения изображений для начинающих. — Текст : электронный // neurohive : [сайт]. — URL: <https://neurohive.io/ru/osnovy-data-science/obzor-metodov-super-razresheniya-izobrazhenij-dlya-nachinajushhih/> (дата обращения: 03.06.2023).
50. Kamila, Ostrowska A Brief History of Python / Ostrowska Kamila. — Текст : электронный // learnpython : [сайт]. — URL: <https://learnpython.com/blog/history-of-python/> (дата обращения: 11.06.2023).
51. What is Python?. — Текст : электронный // educba : [сайт]. — URL: <https://www.educba.com/what-is-python/> (дата обращения: 11.06.2023).
52. Python . — Текст : электронный // habr : [сайт]. — URL: <https://habr.com/ru/hub/python/> (дата обращения: 11.06.2023).
53. Как устроен Docker и почему он популярен. — Текст : электронный // yandex : [сайт]. — URL: <https://cloud.yandex.ru/blog/posts/2022/03/docker-containers> (дата обращения: 11.06.2023).
54. Как HTTPS обеспечивает безопасность соединения: что должен знать каждый Web-разработчик. — Текст : электронный // habr : [сайт]. — URL: <https://habr.com/ru/articles/188042/> (дата обращения: 11.06.2023).

55. Карта бизнес-процесса as-is: от проблем к решениям. — Текст : электронный // dzen : [сайт]. — URL: <https://dzen.ru/a/YyBrB8baHEuwMfJ8> (дата обращения: 11.06.2023).
56. Описание бизнес-процессов Как есть (AS IS) и Как должно быть (TO BE). — Текст : электронный // trinion : [сайт]. — URL: <https://trinion.org/blog/opisanie-biznes-processov-kak-est-as-is-i-kak-dolzno-byt-to-be?ysclid=lir74eybpo17144996> (дата обращения: 11.06.2023).
57. Диаграмма Ганта и как её использовать для управления проектами. — Текст : электронный // cloud.yandex : [сайт]. — URL: <https://cloud.yandex.ru/blog/posts/2023/05/gantt-chart> (дата обращения: 11.06.2023).
58. Сетевой график. — Текст : электронный // kpms : [сайт]. — URL: [https://www.kpms.ru/Implement/Qms\\_Activity\\_Network.htm?ysclid=lir7a1tl nj166199884](https://www.kpms.ru/Implement/Qms_Activity_Network.htm?ysclid=lir7a1tl nj166199884) (дата обращения: 11.06.2023).
59. Что такое риски проекта и как ими управлять Источник: «ОкоCRM» Сайт © <https://okocrm.com>. — Текст : электронный // okocrm : [сайт]. — URL: <https://okocrm.com/blog/riski-proekta/?ysclid=lir7bfplqb564065109> (дата обращения: 11.06.2023).
60. Сайт © <https://okocrm.com>. — Текст : электронный // mail : [сайт]. — URL: [https://health.mail.ru/news/uspets\\_za\\_19\\_minut](https://health.mail.ru/news/uspets_za_19_minut) (дата обращения: 11.06.2023).
61. Какое количество часов в неделю обязан работать врач-кардиолог на 1 ставку ведя амбулаторный приём?. — Текст : электронный // [www.9111.ru](http://www.9111.ru) : [сайт]. — URL: <https://www.9111.ru/questions/18812021/?ysclid=lir7p1zcis466050486> (дата обращения: 11.06.2023).
62. Management of Heart Failure With Preserved Ejection Fraction. — Текст : электронный // guidelinecentral : [сайт]. — URL:

<https://www.guidelinecentral.com/guidelines/acc/> (дата обращения:  
11.06.2023).

63. Supervised Exercise Training for Chronic Heart Failure With Preserved Ejection Fraction. — Текст : электронный // guidelinecentral : [сайт]. — URL: <https://www.guidelinecentral.com/guidelines/acc/> (дата обращения: 11.06.2023).