

На правах рукописи



ДАНИЛОВ ВЯЧЕСЛАВ ВЛАДИМИРОВИЧ

**МЕТОДЫ И АЛГОРИТМЫ СЕГМЕНТАЦИИ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ
НА ОСНОВЕ МАШИННОГО ОБУЧЕНИЯ**

Специальность 05.13.01

Системный анализ, управление и обработка информации
(научные исследования)

АВТОРЕФЕРАТ

диссертации на соискание учёной степени
кандидата технических наук

Томск – 2020

Работа выполнена в федеральном государственном автономном образовательном учреждении высшего образования «Национальный исследовательский Томский политехнический университет»

Научный руководитель: **Гергет Ольга Михайловна**
доктор технических наук, доцент

Официальные оппоненты: **Ходашинский Илья Александрович**
доктор технических наук, профессор, ФГБОУ ВО «Томский государственный университет систем управления и радиоэлектроники», профессор кафедры комплексной информационной безопасности электронно-вычислительных систем


Захарова Алёна Александровна
доктор технических наук, доцент, ФГБОУ ВО «Брянский государственный технический университет», заместитель первого проректора по учебной работе

Защита состоится «16» сентября 2020 г. в 15 час. 00 мин. на заседании диссертационного совета ДС.ТПУ.15 при федеральном государственном автономном образовательном учреждении высшего образования «Национальный исследовательский Томский политехнический университет» по адресу: 634034, г. Томск, ул. Советская, д. 84/3, ауд. 214.

С диссертацией можно ознакомиться в научно-технической библиотеке ФГАОУ ВО «Национальный исследовательский Томский политехнический университет» по адресу: 634034, г. Томск, ул. Белинского, д. 53а и на сайте: dis.tpu.ru.

Автореферат разослан «___» _____ 2020 г.

Учёный секретарь
диссертационного совета



(подпись)

Пак Александр Яковлевич

Актуальность работы. На сегодняшний день существует множество работ, посвящённых сегментации изображений в различных сферах деятельности человека. В свою очередь, работы, направленные на сегментацию медицинских инструментов или анатомических структур, представлены значительно меньшим числом, что объясняется низким качеством выходных данных, большой вариабельностью признаков, малым объёмом выборок, высокой зашумлённостью и т.д. Существующие в настоящее время классические подходы для выполнения сегментации медицинских изображений имеют множество ограничений, одним из которых является каскадность. Алгоритмы на основе каскадности имеют блочную последовательную структуру и в большинстве случаев обладают низкой обобщающей способностью. Способность модели к обобщению заключается в распространении обнаруженных на обучающем множестве зависимостей и закономерностей на новые данные. В дополнении стоит отметить, что каскадные алгоритмы обладают негативным эффектом накопления ошибки.

В ряде исследований алгоритмы сегментации используют предварительно обработанные данные. Подобная реализация хоть и показывает в ряде случаев свою эффективность, тем не менее обладает множеством недостатков, а именно: высоким временем выполнения, низкой вариативностью параметров настройки и слабой адаптацией к предсказанию новых данных.

Другим недостатком классических алгоритмов сегментации, в том числе использующих подход машинного обучения, является использование признаков, синтезированных вручную. Несмотря на то, что существуют эффективные методы по выбору релевантных признаков, сам процесс их создания не всегда является приемлемым для решения медицинских задач. Также стоит отметить, что трёхмерные статические и трёхмерные динамические алгоритмы сегментации представлены небольшим числом исследований. Из-за высокой сложности методов сегментации трёхмерных объектов требуются большие временные затраты, что не позволяет внедрять подобные методы для выполнения обработки данных в реальном масштабе времени.

Большинство современных медицинских модальностей, выполняющих сбор и визуализацию данных в режиме реального времени, не позволяют эффективно распознавать и анализировать сложные динамические структуры. В свою очередь, недостатки программно-аппаратной составляющей минимально инвазивной технологии значительно сокращают спектр возможных операций на сердце. В случае выполнения катетерных операций, актуальность выполнения сегментации обусловлена необходимостью локализации хирургического инструмента относительно оперируемой области. Поскольку направление работы связано с проведением исследований на работающем сердце, существует необходимость в технологии извлечения структурированной информации об объекте интереса из последовательности изображений.

Несмотря на наличие разработанных методов и программных средств, задача сегментации малых объектов, размер которых не превышает 1% от объёма изображения, на зашумлённых трёхмерных данных остаётся не решённой. В связи с этим становится актуальной разработка методов сегментации изображений и визуализации объектов на трёхмерной сцене, в том числе хирургического инструмента и анатомических структур на входных данных низкого качества.

Целью данной работы является создание методов и алгоритмов сегментации на основе машинного обучения, позволяющих повысить точность распознавания и визуализации медицинского инструмента и анатомических структур.

Для достижения поставленной цели в диссертации необходимо решить следующие исследовательские **задачи**:

- Провести анализ существующих методов и алгоритмов локализации и сегментации медицинских инструментов и анатомических структур.
- Разработать алгоритм синтеза трёхмерных эхокардиографических изображений с медицинским инструментом для случаев малого объёма данных, гомогенности и слабой репрезентативности выборки.
- Разработать архитектуру нейронной сети, которая сохраняет градиенты и решает проблему чрезмерной подгонки параметров к зависимостям, содержащимся в обучающем множестве данных.
- Реализовать алгоритм выбора оптимальных гиперпараметров для глубоких нейронных сетей.
- Реализовать метод обучения нейронной сети с использованием циклической скорости обучения и динамического изменения размера батча, позволяющего ускорить сходимость процесса обучения.
- Разработать программное обеспечение и провести вычислительный эксперимент с целью оценки результатов сегментации, полученных на основе предлагаемых методов и алгоритмов.

Объектом исследования является процесс сегментации медицинских изображений.

Предметом исследования являются методы машинного обучения, с помощью которых осуществляется локализация и сегментация изображений, содержащих медицинский инструмент и анатомические структуры.

Методы исследования. Выполненные в диссертационной работе исследования основаны на использовании методов цифровой обработки изображений, математического анализа и моделирования, алгоритмов компьютерного зрения, математической статистики,

методов преобразования и анализа изображений, машинного обучения, распознавания образов и прикладного программирования.

Научная новизна диссертационной работы представлена следующими составляющими:

- Предложена модификация U-net архитектуры в виде V-net архитектуры свёрточной нейронной сети с дополнительными пробросами признаков, наличие которых позволяет решить проблему затухающих градиентов глубоких нейронных сетей. V-net архитектура в среднем на 10% превосходит стандартную U-net архитектуру по точности.
- Разработан алгоритм синтеза медицинского инструмента на трёхмерных ультразвуковых изображениях, который позволяет увеличить гетерогенность используемых данных и автоматизировать процесс разметки. Для точной реконструкции данный алгоритм использует кинематику гибких роботов при совмещении изображений анатомических структур и медицинского инструмента.
- Предложен метод обучения нейронных сетей, основанный на интеграции динамического изменения размера батча и циклической скорости обучения с алгоритмом test-time аугментации на этапе предсказания новых данных. Такая реализация позволяет повысить скорость сходимости по сравнению с классическими методами обучения, использующими статический размер батча и/или постоянное значение скорости обучения.
- Разработан алгоритм выбора гиперпараметров, основанный на последовательном подборе значений параметров посредством использования t-критерия Стьюдента для связанных выборок. Предлагаемый алгоритм позволяет учитывать динамику на прошлых итерациях и не выполнять полный перебор по подмножеству пространства гиперпараметров, что значительно сокращает время подбора оптимальных значений.

Достоверность результатов диссертационного исследования обеспечивается успешным тестированием обученных моделей, а достигнутые результаты коррелируют и согласуются с эталонными, полученными квалифицированными специалистами в следующих организациях: Boston Children's Hospital (Бостон, США), King's College London (Лондон, Великобритания), Memorial Sloan Kettering Cancer Center (Нью-Йорк, США), Vanderbilt University Medical Center (Нэшвилл, США), IRCAD Hôpitaux Universitaires (Страсбург, Франция). Принятые в работе авторские решения основаны на известных и проверенных методах разработки глубоких нейронных сетей для обработки медицинских графических данных. Положения диссертации базируются на анализе и практических результатах использования машинного обучения, обобщении опыта в области математического моделирования и распознавания образов. Достоверность результатов, работоспособность разработанных методов и алгоритмов подтверждается соответствием экспериментальных данных, полученных в ходе исследований и опытного внедрения.

Практическая значимость работы заключается в следующем:

- Разработанное программное обеспечение позволяет сопровождать хирургические вмешательства, в том числе минимально инвазивные операции, а также снизить вероятность врачебной ошибки.
- Научные исследования по визуализации медицинских инструментов в анатомических структурах могут быть внедрены в медицинские образовательные программы и использоваться в научно-исследовательских целях. Полученные трёхмерные модели использованы студентами и медицинскими работниками в целях моделирования поведения хирургического инструмента при проведении малоинвазивных операций, а также для симуляционного и имитационного обучения новым методам диагностики и вмешательств.
- Модели и методы, использующиеся для обработки медицинских изображений, могут применяться при выполнении минимально инвазивных вмешательств в хирургической онкологии, нейрохирургии и сосудистой хирургии.
- В связи с отсутствием в настоящее время предварительно обученных трёхмерных нейронных сетей для выполнения сегментации, все полученные модели могут использоваться в качестве первичной инициализации весов. В таком случае время обучения новых моделей значительно снизится.

Положения, выносимые на защиту:

- Метод сегментации на основе V-net архитектуры с плотными пробросами признаков позволяет решить задачу сегментации не только медицинского инструмента, но и анатомических структур с высокой точностью. При тестировании используемого метода точность сегментации катетера составила $93.6 \pm 2.4\%$, а левого предсердия – $92.2 \pm 2.7\%$.
- Алгоритм синтеза ультразвуковых данных позволяет повысить точность сегментации за счёт увеличения репрезентативности обучающей выборки и автоматизировать процесс разметки сгенерированных данных. Тестирование стандартной и разреженной U-net архитектур выявило положительную тенденцию изменения точности за счёт увеличения количества синтетических примеров в обучаемых выборках. Точность сегментации для разреженной U-net архитектуры составила $86.5 \pm 3.6\%$, $88.3 \pm 3.1\%$, $89.8 \pm 3.5\%$ и $92.6 \pm 2.2\%$ при RDR равном 1.00, 0.50, 0.33 и 0.25 соответственно.
- Метод обучения нейронных сетей на основе использования динамического размера батча и циклической скорости обучения, а также предсказания на основе алгоритма test-time аугментации позволяет в среднем на 6.0% точнее выполнять предсказания новых данных, а также повысить обобщающую способность и надёжность модели. Использование данного метода увеличило точность сегментации медицинского инструмента и анатомических структур в среднем на 3.0% и 6.3% соответственно.

– Алгоритм выбора гиперпараметров позволяет снизить время поиска оптимальных значений параметров модели по сравнению с такими алгоритмами, как Grid Search и Randomized Search. Предлагаемый алгоритм учитывает динамику точности модели на прошлых итерациях и не проходит по всему подмножеству пространства гиперпараметров. При использовании предлагаемого подхода с 11 гиперпараметрами количество моделей для оптимизации составило 690 вместо 204 374 016 для Grid Search и Randomized Search.

Внедрение. Разработанные методы и алгоритмы сегментации используются в федеральном государственном бюджетном научном учреждении «Научно-исследовательский институт комплексных проблем сердечно-сосудистых заболеваний» (Кемерово, Россия) и адаптированы для выполнения сегментации стеноза при проведении диагностики коронарных артерий на основе данных ангиографии (акт о внедрении от 07.05.2019). Материалы диссертационной работы используются при проведении практических занятий по дисциплинам «Машинное обучение», «Технология обработки информации», «Теория распознавания образов», «Нейронные сети», «Методы интеллектуальной обработки и анализа изображений» для магистрантов направлений 230100 "Информатика и вычислительная техника" и 230400 "Информационные системы и технологии" в Томском политехническом университете (акт о внедрении от 05.09.2019).

Реализация результатов. Результаты диссертационного исследования использованы при выполнении следующих научно-исследовательских проектов: государственное задание "Наука" №4003/БЧ «Разработка новых моделей и методов для диагностики и лечения заболеваний сердца и нарушений мозгового кровообращения»; государственное задание "Наука" №17.8205.2017/БЧ «Моделирование и алгоритмизация процессов обработки, анализа и репрезентации графических данных в режиме реального времени для проведения эндоваскулярных операций на сердце»; грант РФФИ №18-75-10061 "Исследование и реализация концепции роботизированного малоинвазивного протезирования клапана аорты"; государственное задание "Наука" №FFSWW-2020-0014 «Разработка научных основ технологии роботизированной мультипараметрической томографии на основе методов обработки больших данных и машинного обучения для исследования перспективных композиционных материалов».

Апробация. Работа прошла апробацию на следующих конференциях: III International Scientific Conference on Information Technologies in Science, Management, Social Sphere and Medicine (Томск, Россия, 2016); XV Международная научно-практическая конференция студентов, аспирантов и молодых учёных (Томск, Россия, 2017); 27-я Международная конференция по компьютерной графике и машинному зрению «ГрафиКон» (Пермь, Россия, 2017); Computer Assisted Radiology and Surgery International Conference and Exhibition (Берлин, Германия, 2018); V International workshop "Critical infrastructures: Contingency management,

Intelligent, Agent-based, Cloud computing and Cyber security” (Иркутск, Россия, 2018); 28-я Международная конференция по компьютерной графике и машинному зрению «ГрафиКон» (Томск, Россия, 2018); 18th International Conference on Mechatronics (Брно, Чехия, 2018); 14th International Conference on Electromechanics and Robotics "Zavalishin's Readings" (Курск, Россия, 2019); International Workshop on “Photogrammetric and computer vision techniques for video surveillance, biometrics and biomedicine” (Москва, Россия, 2019); 29-я Международная конференция по компьютерной графике и машинному зрению «ГрафиКон» (Брянск, Россия, 2019); 14th International Forum on Strategic Technology (IFOST 2019) (Томск, Россия, 2019); I Всероссийский Конгресс с международным участием «Физиология и тканевая инженерия сердца и сосудов: от клеточной биологии до протезирования» (Кемерово, Россия, 2019).

Публикации. Основные материалы диссертации опубликованы в 22 печатных работах, из которых: 4 публикации в рецензируемых журналах, рекомендованных ВАК РФ; 13 публикаций в изданиях, индексируемых в базах научного цитирования Scopus и Web of Science (в том числе 4 работы типа Article, 9 работ типа Conference paper); 5 публикаций в других изданиях. Получены 5 свидетельств о государственной регистрации программ для ЭВМ, а также получено решение о выдаче патента на изобретение.

Личный вклад соискателя. Основные научные результаты, выносимые на защиту, получены автором лично. Данная работа выполнена в сотрудничестве с учёными и исследователями, оказавшими содействие при проведении настоящего исследования, а именно: постановка задач исследования по теме диссертации выполнена совместно с научным руководителем Гергет О.М. (Томский политехнический университет) и кардиохирургом Васильевым Н.В. (Boston Children’s Hospital, Harvard Medical School); обзор существующих алгоритмов анализа, обработки и визуализации медицинских данных выполнен совместно со Скирневским И.П. (Центр Финансовых Технологий) и научным руководителем Гергет О.М. (Томский политехнический университет); сбор, разметка и валидация ультразвуковых данных при проведении минимально инвазивных вмешательств выполнены совместно с кардиохирургом Васильевым Н.В. (Boston Children’s Hospital, Harvard Medical School); разработка алгоритма синтеза ультразвуковых данных сердца и медицинского инструмента выполнена совместно с Манаковым Р.А. (Научно-исследовательская лаборатория «Гамма технологии») и Колпащиковым Д.Ю. (Лаборатория дизайна медицинских изделий, Томский политехнический университет); разработка архитектуры нейронной сети выполнена совместно с María J. Ledesma-Carbayo, David Bermejo Peláez и Luis Alfonso Hernández Gómez (Biomedical Imaging Technologies Laboratory, Universidad Politécnica de Madrid).

Благодарности. Автор выражает искреннюю благодарность María J. Ledesma-Carbayo (Biomedical Imaging Technologies Laboratory, Universidad Politécnica de Madrid) за

предоставленный сервер с видеокартами Titan X и Titan Xp; Farid Melgani (Signal Processing and Recognition Laboratory, Università degli Studi di Trento) за курирование исследования, посвящённого извлечению и выявлению наиболее релевантных и информативных признаков; Alejandro F. Frangi (Center for Computational Imaging and Simulation Technologies in Biomedicine, University of Leeds) за оборудование для выполнения обучения/валидации моделей и доступ к платформам MULTI-X, Amazon Web Services и UK Biobank.

Структура и объём диссертации. Диссертация состоит из введения, 3 глав, заключения, списка использованной литературы из 179 наименований и 2 приложений. Работа изложена на 191 странице и включает 85 рисунков и 36 таблиц.

СОДЕРЖАНИЕ РАБОТЫ

Введение. В данной части работы обоснована актуальность темы исследования, сформулированы цель и задачи работы, определена научная новизна, а также отражены практическая значимость и положения, выносимые на защиту.

Глава 1. В данной главе рассматриваются алгоритмы и методы сегментации и локализации различных объектов, проводится анализ современных программно-аппаратных решений для обработки и визуализации медицинских данных.

Показано, что на текущий момент существует большой спектр систем и средств, выполняющих обработку и последующую визуализацию медицинских данных. Подобные решения представлены рядом программных продуктов, которые различаются по функциям, направленности и сложности. Выделены два ключевых способа реализации подобных программных комплексов. Первый способ предполагает, что комплексы обработки медицинских изображений встраиваются в аппаратную часть, а затем поставляются совместно с аппаратным обеспечением. Второй способ заключается в реализации и установке систем в качестве самостоятельного программного обеспечения. Наиболее актуальными и перспективными системами являются те, что поставляются и реализуются независимо от аппаратной части, так как позволяют выполнять обработку изображений независимо от оборудования, на котором они получены.

В главе также обсуждаются достоинства и недостатки медицинских модальностей. Отмечено, что такие модальности как МРТ и КТ обладают достаточно высоким качеством, однако имеют высокое время сбора данных, а также их невозможно использовать при хирургических вмешательствах. В свою очередь, эндоваскулярные процедуры на сердце практически всегда проходят под контролем эхокардиографии или флюороскопии. Наличие ряда недостатков, присущих подобным модальностям, среди которых низкое качество выходных

данных, ограниченная область видимости, отсутствие глобального контекста, значительное число артефактов и теней, высокий спекл-шум и низкий контраст, не позволяет эффективно выполнять хирургические вмешательства. Очевидно, что использование классических систем двухмерной динамической эхокардиографии или флюороскопии сильно ограничивает выполнение сложных и точных манипуляций внутри анатомических структур, а также не позволяет расширить спектр эндоваскулярных реконструктивных операций.

За счёт популяризации кардиохирургической катетеризации возникла потребность определения положения медицинского инструмента относительно анатомических структур. В связи с этим было предложено множество методов и алгоритмов по детектированию катетера внутри сердца, например, роботизированная локализация или трекинг на основе электромагнитных сенсоров. Однако подобные техники требуют наличия дополнительного оборудования, что влечёт за собой большие затраты при их использовании в клинической практике. Менее затратной альтернативой является обнаружение медицинского инструмента с использованием изображений. На сегодняшний день было предложено множество методов по локализации медицинского инструмента и анатомических структур, однако большинство из них носили лишь экспериментальный характер. Важно добавить, что особенностью подобных методов является их строение по принципу каскадности. Такой подход легко интерпретируется, однако имеет свойство к накоплению ошибки и обладает слабой обобщающей способностью. При масштабировании и использовании этого подхода на других данных приходится тонко перенастраивать параметры блоков обработки. Необходимо подчеркнуть, что методы, построенные по такому принципу, зачастую тестируются на небольшой выборке. Другой класс методов предполагает использование данных флюороскопии. Несмотря на то, что аппараты флюороскопии de-facto являются базовым оборудованием операционных комнат, использование такой модальности весьма затруднительно. Это объясняется тем, что катетер на таких изображениях довольно легко различим, однако анатомические структуры без введения контрастного вещества высокой плотности отсутствуют. В связи с этим, эффективным является подход, основанный на обработке динамических трёхмерных данных эхокардиографии.

Анализ исследований показал, что базирующиеся на свёрточных нейронных сетях методы локализации и сегментации трёхмерных данных эхокардиографии не имеют каскадности, обрабатывают сырые данные без дополнительной предобработки, характеризуются высокой обобщающей способностью и масштабируемостью.

Глава 2. В данной главе описаны предлагаемые методы и алгоритмы, которые позволяют осуществить процедуру сегментации медицинского инструмента и анатомических структур. Ключевой частью работы является глубокая свёрточная нейронная сеть, выполняющая сегментацию трёхмерных изображений. Тестирование представленного метода и модели

сегментации выполнялось на данных компьютерной и магнитно-резонансной томографии. В качестве области интереса выступали пять анатомических структур. Сравнение полученных результатов проводилось с 11 лучшими моделями соревнования «Medical Segmentation Decathlon», проходившего в рамках конференции «Medical Image Computing and Computer Assisted Intervention (MICCAI)».

В связи с ярко выраженной гомогенностью выборочных данных, в диссертационной работе предложен алгоритм синтеза изображений, в частности, медицинского инструмента внутри анатомических структур, который учитывает реальную кинематику инструмента. Концепция данного алгоритма заключается в размещении медицинского инструмента в пустой полости анатомической структуры, например, в камере сердца и его последующей трансформации. Для создания случайных трансформаций катетера предлагается использовать систему координат, которая, вне зависимости от изгиба и формы объекта, позволит однозначно идентифицировать каждую точку. Это даст возможность трансформировать изображение под любую заданную конфигурацию. За основу предлагается взять цилиндрическую систему координат, модифицировав её заменой оси Z на сплайн, вдоль которого отсчитывается h -координата. В качестве трансформации использованы изгиб, скручивание, масштабирование и смещение. Реализованный алгоритм расчёта кинематики медицинского инструмента позволяет создать дополнительную выборку данных, где инструмент может находиться во всех реально существующих положениях анатомической структуры и принимать разную форму. Для генерации искусственного примера трёхмерной эхокардиографии сердца, содержащей дистальный конец катетера, необходимы: трёхмерное изображение катетера, трёхмерное изображение сердца, начальная точка и ориентация катетера. Предложенный алгоритм позволяет увеличить обучающую выборку и автоматизировать процесс разметки.

D.E. Rumelhart, G.E. Hinton и R.J. Williams в работе «Learning representations by back-propagating errors» показали сходимость алгоритма обратного распространения ошибки. Однако алгоритм сходится при скорости обучения близкой к нулю. Последнее ведёт к затуханию градиентов, а именно к бесконечно малому изменению весов. Неглубокие сети, имеющие малое количество слоёв, как правило, не обладают этим недостатком, так как подобный эффект не успевает накапливаться при обратном проходе алгоритма. В свою очередь, при обучении глубоких архитектур эффект обучения на основе алгоритма обратного распространения ошибки не доходит до начальных слоёв. Это объясняется тем, что градиенты весов в начальных слоях становятся предельно малыми за счёт постепенно уменьшающихся градиентов на более поздних слоях. При прямом прохождении функции активации позволяют скомпенсировать данный недостаток. Однако обратный проход метода обратного распространения ошибки линеен, поэтому для того, чтобы скомпенсировать эффект затухания градиентов в архитектуре

нейронной сети предлагается внедрить пробросы признаков. Пробросы дают возможность скомпенсировать затухание за счёт увеличения значений весов и производной в точке. Принимая во внимание вышесказанное, предложенная V-net архитектура нейронной сети для сегментации отражена ниже на рисунке 1.

В предлагаемой архитектуре каждый слой соединяется со всеми последующими слоями с помощью конкатенации. Тем самым, слой l получает карты признаков всех предшествующих слоёв $x_0, \dots, x_{l-1}$:

$$x_l^1 = H_l^1([x_l^1, \dots, x_{l-1}^1]) \quad (1)$$

$$x_l^2 = H_l^2([x_l^2, \dots, x_{l-1}^2]) \quad (2)$$

где $[x_l^1, \dots, x_{l-1}^1]$ и $[x_l^2, \dots, x_{l-1}^2]$ – конкатенации карт признаков для энкодера и декодера соответственно. Подобное разделение вводится ввиду того, что в двух половинах используются различные нелинейные трансформации и разный порядок следования слоёв.

В зависимости от архитектуры нейронной сети ландшафт функции потерь может значительно отличаться. Так, неглубокие нейронные сети зачастую имеют выпуклые широкие регионы. В свою очередь, более глубокие архитектуры сетей становятся хаотичными, спонтанными и слабо выпуклыми, что негативно сказывается на процессе обучения. В связи с этим было предложено несколько методов, которые позволяют более эффективно провести процесс обучения нейронной сети. На сегодняшний день широко используется техника отжига при обучении. Использование данной техники позволяет обучать нейронные сети, постепенно






Рисунок 1 – V-net архитектура с плотными пробросами признаков

снижая скорость обучения. Однако основной проблемой обучения на основе отжига является малоэффективное прохождение седловых точек и локальных минимумов. В связи с этим, в диссертационной работе предлагается использовать концепцию циклической скорости обучения. Для обучения модели было предложено 4 циклических закона изменения скорости обучения, графики которых отражены на рисунке 2.


Другой проблемой при обучении нейронных сетей является выбор оптимального размера батча. С одной стороны, небольшие значения батча ведут к лучшей сходимости модели. С другой стороны, большие значения батча обеспечивают более производительное распараллеливание, что в свою очередь улучшает вычислительную эффективность и масштабируемость, а также сокращает время обучения. В связи с этим, в работе предлагается обучать модель, используя непостоянный размер батча. Процесс обучения начинается с относительно большого размера батча, что обеспечивает быстрое схождение алгоритма градиентного спуска в область минимума. При отсутствии улучшения функции потерь на валидационной выборке происходит уменьшение размера батча по определённому закону. После чего процесс итеративно повторяется. Финальное значение размера батча может варьироваться в зависимости от типа данных, их количества, времени обучения и т.д. В данной работе при




(а) Триангулярно-циклическая скорость обучения



(б) Шаговая триангулярно-циклическая скорость обучения



(в) Экспоненциальная триангулярно-циклическая скорость обучения



(г) Синусоидальная циклическая скорость обучения

Рисунок 2 – Законы изменения циклической скорости обучения

обучении модели, выполняющей семантическую сегментацию, использовалась последовательность Фибоначчи, начинающаяся с размера батча равного 8. Представленный метод обучения схематично изображён на рисунке 3.

Другим ключевым пунктом, описанным в работе, является алгоритм выбора оптимальных гиперпараметров. Гиперпараметрами модели являются её степени свободы, которые напрямую не оптимизируются при обучении, но значительно влияют на окончательный результат. Широко известными являются алгоритмы Grid Search (проход по сетке) и Randomized Search (семплирование точек гиперпараметров из фиксированного распределения). Недостатком данных подходов является перебор множества заведомо неудачных точек пространства гиперпараметров, что кратно увеличивает время оптимизации. Другим недостатком является то, что при большом количестве гиперпараметров требуется увеличивать размер ячейки/шага, что в свою очередь уменьшает вероятность попадания в глобальный оптимум. В связи с тем, что проверка каждой точки пространства гиперпараметров V-net модели вычислительно дорога, предложенный в работе алгоритм позволяет приблизиться к оптимуму за гораздо меньшее число шагов. Ключевая идея данного алгоритма сводится к выбору модели на определённом разбиении кросс-валидации, которая выполняет сегментацию с более высокой точностью. Выбор происходит за счёт сравнения с нулём среднего попарных разностей результатов двух моделей на соответствующих разбиениях. Нулевая гипотеза H_0 данного подхода состоит в том, что сравниваемые модели дают одинаковые результаты. С помощью критерия Стьюдента для связанных выборок оценивается обобщённое значение Т-критерия. Чем больше обобщённое значение Т-критерия отклоняется от нуля, тем меньше вероятность выполнения нулевой гипотезы. Для расчёта t-статистики используется следующая формула:

$$T(X_1^n, X_2^n) = \frac{M_d}{\sigma_d / \sqrt{n}} = \frac{E(X_1) - E(X_2)}{\sigma_d / \sqrt{n}} \quad (3)$$

где X_1^n, X_2^n – массивы значений метрики по тестовым разбиениям для сравниваемых моделей, M_d – среднее арифметическое разностей показателей, σ_d – среднее квадратическое отклонение




Рисунок 3 – Метод обучения на основе переменного размера батча

попарных разностей, n – число исследуемых экземпляров. Для точной настройки параметров модели вычисляется t -статистика для каждого разбиения, а затем все статистики модели усредняются для получения обобщённого значения T -критерия. Если рассчитанный результат положителен, то базовая модель выполняет сегментацию эффективнее, чем сравниваемая модель. Последнее означает, что гиперпараметры базовой модели позволяют получить более высокую точность сегментации. В связи с этим, модель с наибольшей отрицательной T -статистикой сильнее влияет на точность сегментации. Важным будет заметить, что при использовании данного алгоритма выбор гиперпараметров происходит последовательно. Общее количество гиперпараметров составляет 11, причём каждый гиперпараметр принимает от 3 до 10 значений. Так, при использовании стандартных стратегий Grid Search и Randomized Search общее количество исследуемых моделей составит 204 374 016. В свою очередь, при использовании предлагаемого подхода общее количество моделей для выбора гиперпараметров составит 690.

Для повышения качества сегментации на этапе предсказания был внедрён алгоритм test-time аугментации (ТТА). При использовании данного алгоритма выходное усреднённое предсказание нейронной сети I_{out} рассчитывается следующим образом:

$$I_{out} = \frac{1}{N} \sum_{i=1}^N w_i * f(I_i) \quad (4)$$

где $f(I_i)$ – предсказание нейронной сети для аугментированного изображения I_i , w_i – весовой коэффициент для i -ой трансформации, N – количество трансформаций для предсказания. Процедура предсказания на основе данного алгоритма выполняется с использованием N аугментированных примеров, в отличие от стандартного предсказания новых данных, использующего один пример. Тем самым, выходным результатом нейронной сети является среднее значение N карт вероятностей. Данный алгоритм призван уменьшить ошибку сегментации за счёт использования нескольких примеров. В случае, если модель выполняет предсказания на новых данных неудовлетворительно, использование алгоритма test-time аугментации зачастую повышает шансы модели на более корректное прогнозирование, тем самым увеличивая её точность сегментации.

Глава 3. В данной главе отражены результаты, которые получены при: синтезе ультразвуковых данных; оптимизации гиперпараметров модели; сравнении результатов сегментации, полученных с помощью предлагаемой V-net архитектуры с плотными пробросами признаков с рядом популярных моделей. В качестве оценки надёжности и работоспособности предложенного в работе метода сегментации проводится тестирование нейронной сети как на наборе данных с медицинским инструментом, так и на наборах данных с пятью анатомическими структурами.

Для оценки влияния дополнительных синтетических данных на обобщающую способность были обучены 8 нейронных сетей на основе стандартной и разреженной U-net архитектур. Эти модели в последующем использовались для сегментации реальных данных. Обучение проводилось с учётом вариации параметра RDR. Данный параметр отражает соотношение синтетических и реальных примеров в обучающей выборке и рассчитывается следующим образом:

$$RDR = \frac{RS}{RS + SS} \quad (5)$$

где RS и SS – количество реальных и синтетических изображений соответственно. На основе полученных результатов выявлена положительная тенденция изменения точности при использовании синтетических данных в смешанных выборках. Результаты точности сегментации разреженной U-net архитектуры, а именно индекса Дайса (DSC), отражены на рисунке 4.

На основе выполненной процедуры выбора гиперпараметров были подобраны те значения, которые эффективно выполняют поиск минимума функции потерь, а также позволяют сегментировать различные типы объектов с высокой точностью, в среднем варьирующейся в диапазоне значений от 83% до 96%. Процедура выбора гиперпараметров модели начиналась с оценки типа dropout слоя, а затем итеративно проходила через остальные гиперпараметры, заканчиваясь на оценке количества свёрточных фильтров. Важно отметить, что базовая нейронная сеть, для которой не осуществлялся подбор гиперпараметров на основе предложенного алгоритма, имела точность равную $46.4 \pm 34.6\%$. В результате проведения процедуры выбора гиперпараметров точность предлагаемой модели составила $90.6 \pm 3.3\%$. Полученная улучшенная модель в дальнейшем использовалась для выполнения сегментации не только медицинского инструмента, но и анатомических структур. Сравнение базовой и улучшенной моделей отражено ниже в таблице 1.




Рисунок 4 – Индекс Дайса для разреженной U-net архитектуры при разных значениях RDR

Для оценки сегментации медицинского инструмента использовались данные, полученные в Boston Children's Hospital при выполнении кардиохирургических операций. Инструмент был введён в полость левого желудочка. Исходное количество данных составило 250 трёхмерных экземпляров эпикардальной эхокардиографии. Обученная V-net модель с плотными пробросами признаков тестировалась с использованием алгоритма test-time аугментации. Дополнительно было проведено сравнение предлагаемой модели с другими классическими моделями. Результаты оценки точности сегментации, полученные с использованием различных моделей, отражены на рисунке 5. На основе полученных результатов видно, что модели FCN и SegNet выполняют сегментацию некачественно, а их выходная точность составила $12.4 \pm 6.4\%$ и $19.0 \pm 8.5\%$ соответственно. Это объясняется рядом причин, а именно: недостаточной сложностью моделей, затуханием градиентов при использовании глубоких архитектур, отсутствием дополнительных пробросов карт признаков и т.д. В свою очередь, архитектуры, использующие проброс признаков, позволяют выполнить сегментацию качественнее. Стандартная архитектура U-net позволила получить точность сегментации равную $80.5 \pm 5.8\%$. Точность предлагаемой V-net архитектуры с использованием алгоритма ТТА на обучающей выборке составила $94.1 \pm 2.0\%$, а на тестовой – $93.6 \pm 2.4\%$. Отметим тот факт, что на данных с медицинским инструментом модель Pseudo 3D U-net выполняет сегментацию точнее

Таблица 1 – Сравнительная оценка базовой и оптимальной моделей

Гиперпараметр	Базовая модель	Оптимальная модель
Dropout	–	Стандартный
Метод нормализации	–	Instance
Метод оптимизации	SGD	Adam
Метод регуляризации	–	–
Размер батча	1	2
Тип активации	ReLU	ELU
Скорость обучения	0.001	0.005
Метод скорости обучения	ConLR	SCLR
Метод инициализации	Ones	He normal
Дилатация	1	1
Коэффициент свёрточных фильтров	1	4
Количество весов	1 268 066	20 281 253

полноценной трёхмерной модели на основе стандартной U-net архитектуры. В связи с тем, что архитектура Pseudo 3D U-net использует двухмерные тензоры для предсказания новых данных, такая модель может эффективнее использоваться на устройствах с малой вычислительной мощностью.

Результат сегментации данных катетера на основе предлагаемой V-net модели отражён на рисунке 6. Данные рисунки отражают сравнение результатов сегментации (белые маски), полученных с помощью модели на основе V-net архитектуры и эталонной разметки (красные маски), полученной квалифицированным клиницистом. Анализ результатов показал, что разница между масками незначительная, что говорит о высокой точности представленного метода сегментации и нейронной сети V-net.

В целях оценки работоспособности и надёжности предложенных алгоритмов и методов, модель на основе V-net архитектуры использовалась для выполнения сегментации таких анатомических структур, как левое предсердие, поджелудочная железа, селезёнка, гиппокамп и печень. Все изображения были собраны в рамках проведения медицинских процедур, после чего переформатированы в формат NIfTI и деперсонализированы. Полученные результаты точности сегментации на тестовом наборе отражены в таблице 2.

В **заключении** отражены ключевые результаты, которые были получены при решении поставленных задач.

В **приложении 1** приведены акты о внедрении результатов в Научно-исследовательский институт комплексных проблем сердечно-сосудистых заболеваний (г. Кемерово) и Томском политехническом университете (г. Томск).

В **приложении 2** представлены свидетельства о государственной регистрации программ для ЭВМ и решение о выдаче патента на изобретение.




Рисунок 5 – Оценка точности сегментации катетера на основе тестовых данных

Таблица 2 – Результат сегментации анатомических структур

Анатомическая структура	Тип данных	Количество данных	Источник данных	Индекс Дайса, %	
				V-net	V-net (TTA)
Левое предсердие	MPT	30	King's College London	87.9±2.6	92.2±2.7
Поджелудочная железа	КТ	420	Memorial Sloan Kettering Cancer Center	68.6±11.6	82.9±5.8
Селезёнка	КТ	61	Memorial Sloan Kettering Cancer Center	85.4±8.0	93.6±1.6
Гиппокамп	MPT	394	Vanderbilt University Medical Center	91.7±1.7	94.9±1.5
Печень	КТ	201	IRCAD Hôpitaux Universitaires	94.5±1.6	95.9±1.0




Рисунок 6 – Сегментация данных катетера, полученная с помощью модели V-net (TTA)

ОСНОВНЫЕ РЕЗУЛЬТАТЫ И ВЫВОДЫ РАБОТЫ

При выполнении данной диссертационной работы были достигнуты следующие основные результаты:

1. Оценка современного состояния сферы информационных технологий в медицине показала, что консервативность и слабая развитость средств трёхмерной обработки и визуализации сокращают спектр реконструктивных вмешательств. На основе литературного анализа выявлено, что множество методов и алгоритмов сегментации опираются на каскадность и предварительную обработку данных, что делает их не универсальными, усложняет настройку внутренних параметров, а также понижает обобщающую способность.

2. Алгоритм синтеза трёхмерных изображений с медицинским инструментом позволил автоматизировать процесс разметки данных, а также увеличить точность сегментации за счёт увеличения репрезентативности и гетерогенности обучающей выборки. На основе тестирования стандартной и разреженной U-net архитектур была выявлена тенденция к увеличению точности сегментации при увеличении количества синтетических примеров в обучаемых выборках. Точность сегментации для разреженной U-net архитектуры составила $86.5 \pm 3.6\%$, $88.3 \pm 3.1\%$, $89.8 \pm 3.5\%$ и $92.6 \pm 2.2\%$ при RDR равном 1.00, 0.50, 0.33 и 0.25 соответственно.

3. В качестве основной концепции для решения задачи сегментации выбрано машинное обучение. В работе предложено использовать модификацию U-net архитектуры – V-net архитектуру с пробросами. Главным отличием представленной архитектуры является дополнительное внедрение плотных пробросов признаков не только с энкодера в декодер, но и внутри самих структур. За счёт такого решения удаётся удерживать значения градиентов на приемлемом уровне и тем самым нивелировать проблему их затухания. На основе полученных результатов стандартная модель U-net достигла точности сегментации равной $80.5 \pm 5.8\%$, в свою очередь точность предлагаемой модели V-net с пробросами признаков составила $90.6 \pm 3.3\%$.

4. Для более эффективного обучения нейронной сети были разработаны алгоритм изменения размера батча и алгоритм изменения скорости обучения. Данные алгоритмы позволяют успешно проходить седловые точки, миновать локальные минимумы, а в случае попадания в последние эффективнее из них выходить. Такая реализация процесса обучения позволяет сократить время обучения нейронной сети.

5. Внедрение дополнительного алгоритма test-time аугментации повысило точность сегментации катетера в среднем на 3%. При использовании стандартной V-net архитектуры точность сегментации на тестовой выборке составила $90.6 \pm 3.3\%$, в свою очередь использование алгоритма test-time аугментации повысило точность сегментации до уровня $93.6 \pm 2.4\%$.

6. В целях выбора оптимальных значений гиперпараметров в работе предложен алгоритм оптимизации гиперпараметров модели, основанный на оценке t-критерия Стьюдента для связанных выборок. В отличие от таких подходов, как Grid Search или Randomized Search, предлагаемый алгоритм позволяет учитывать динамику на прошлых итерациях и не выполнять полный перебор по подмножеству пространства гиперпараметров, что значительно сокращает время поиска оптимальных значений. Подходы Grid Search и Randomized Search заведомо перебирают множество неудачных положений без учёта прошлых значений гиперпараметров. Так, при оптимизации 11 гиперпараметров общее количество моделей для подходов Grid Search или Randomized Search будет равным 204 374 016. В свою очередь, при использовании предлагаемого подхода количество моделей для оптимизации гиперпараметров составит 690.

СПИСОК ПУБЛИКАЦИЙ ПО ТЕМЕ ДИССЕРТАЦИИ

Публикации в журналах, рекомендованных ВАК России

1. **Данилов В.В.**, Гергет О.М., Скирневский И.П., Манаков Р.А., Колпашиков Д.Ю. Сегментация на основе распространения динамически изменяемых суперпикселей // Программирование. 2020. № 3. С. 3–15.
2. **Данилов В.В.** Алгоритм выбора оптимальных значений гиперпараметров нейронных сетей на основе t-критерия Стьюдента // Cloud of Science. 2020. Т. 7, № 1. С. 165-179.
3. **Данилов В.В.**, Скирневский И.П., Гергет О.М. Алгоритм локализации катетера на данных эхокардиографии с помощью метода поиска максимально устойчивых экстремальных областей и анализа формы // Вестник новых медицинских технологий. 2018. Т. 25, № 2. С. 113–120.
4. **Данилов В.В.**, Колпашиков Д.Ю., Лаптев Н.В. Автоматическое управление непрерывным роботом с использованием алгоритма FABRIK // Моделирование, оптимизация и информационные технологии. 2019. Т. 7, № 4. С. 1–11.

Публикации в изданиях, индексируемых Scopus и Web of Science

1. **Danilov V.V.**, Skirnevskiy I.P., Manakov R.A., Gerget O.M., Melgani F. Feature selection algorithm based on PDF / PMF area difference // Biomedical Signal Processing and Control. 2020. Vol. 57. P. 1–15.
2. **Danilov V.V.**, Gerget O.M., Skirnevskiy I.P., Manakov R.A., Kolpashchikov D.Y. Segmentation Based on Propagation of Dynamically Changing Superpixels // Programming and Computer Software. 2020. Vol. 46, № 3. P. 195–206.

3. **Danilov V.V.**, Skirnevskiy I.P., Manakov R.A., Kolpashchikov D.Y., Gerget O.M. Segmentation Algorithm Based on Square Blocks Propagation // Proceedings of the 29th International Conference on Computer Graphics and Vision / ed. Galaktionov V. et al. Aachen: CEUR Workshop Proceedings, 2019. P. 148–154.
4. **Danilov V.V.**, Skirnevskiy I.P., Manakov R.A., Kolpashchikov D.Y., Gerget O.M., Frangi, A.F. Ray-based segmentation algorithm for medical imaging // ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. International Workshop on “Photogrammetric & Computer Vision Techniques for Video Surveillance, Biometrics and Biomedicine”. Moscow, Russia, 2019. Vol. XLII-2/W12. P. 37–45.
5. Kolpashchikov D.Y., Laptev N.V., Manakov R.A., **Danilov V.V.**, Gerget O.M., Meshcheryakov R.V. Motion Planning Algorithm for continuum Robots Bending over Obstacles // III International Conference on Control in Technical Systems. Saint Petersburg, Russia: IEEE, 2019. P. 269–272.
6. Kolpashchikov D.Yu., **Danilov V.V.**, Laptev N.V., Skirnevskiy I.P., Manakov R.A., Gerget O.M., Meshcheryakov R.V. Inverse Kinematics for Steerable Concentric Continuum Robots // Proceedings of 14th International Conference on Electromechanics and Robotics “Zavalishin’s Readings”. Smart Innovation, Systems and Technologies. Kursk, Russia, 2019. № 154. P. 89–100.
7. **Danilov V.V.**, Skirnevskiy I.P., Manakov R.A., Kolpashchikov D.Yu., Gerget O.M., Melgani F. Catheter detection and segmentation in volumetric ultrasound using SVM and GLCM // Scientific Visualization. 2018. Vol. 10, № 4. P. 30–39.
8. **Danilov V.V.**, Skirnevskiy I.P., Gerget O.M., Shelomentcev E.E., Kolpashchikov D.Yu., Vasilyev N.V. Efficient workflow for automatic segmentation of the right heart based on 2D echocardiography // International Journal of Cardiovascular Imaging. Springer Netherlands, 2018. Vol. 34, № 2. P. 1–15.
9. **Danilov V.V.**, Skirnevskiy I.P., Manakov R.A., Kolpashchikov D.Yu., Gerget O.M., Melgani F. Image-based algorithm for the catheter recognition based on GLCM // Proceedings of the 28th International Conference on Computer Graphics and Vision. Tomsk, 2018. P. 252–257.
10. **Danilov V.V.**, Skirnevskiy I.P., Gerget O.M., Manakov R.A. Automatic 2D Segmentation of an Intracardiac Catheter Based on MSER Blob Detector and Eccentricity // Proceedings of the Vth International workshop “Critical infrastructures: Contingency management, Intelligent, Agent-based, Cloud computing and Cyber security” (IWCI 2018). Irkutsk, Russia: Atlantis Press, 2018. P. 26–30.
11. Kolpashchikov D.Yu., Laptev N.V., **Danilov V.V.**, Skirnevskiy I.P., Manakov R.A., Gerget O.M. FABRIK-Based Inverse Kinematics for Multi-Section Continuum Robots // Proceedings of the 18th International Conference on Mechatronics. Brno, Czech Republic: IEEE, 2018. P. 1–8.

12. **Danilov V.V.**, Skirnevskiy I.P., Gerget O.M. Segmentation of anatomical structures of the heart based on echocardiography // Journal of Physics Conference Series. 2017. Vol. 803, № 1. P. 1–6.

13. **Danilov V.V.**, Litvinov R.G., Gerget O.M. Mathematical Modeling of the Electrical Activity of the Heart // Proceedings of the 2016 Conference on Information Technologies in Science, Management, Social Sphere and Medicine. Tomsk, Russia: Atlantis Press, 2016. Vol. 51. P. 187–191.

Публикации в других изданиях

1. Manakov R.A., Kolpashchikov D.Y., Laptev N.V., **Danilov V.V.**, Skirnevskiy I.P., Gerget O.M. Visual shape and position sensing algorithm for a continuum robot // 14th International Forum on Strategic Technology (IFOST-2019). Tomsk, Russia: TPU Publishing House, 2019. P. 399–402.

2. Колпашиков Д.Ю., Лаптев Н.В., Манаков Р.А., **Данилов В.В.**, Гергет О.М., Мещеряков Р.В. Планирование движения непрерывных роботов с огибанием препятствий // Всероссийская научная конференция по проблемам управления в технических системах. Санкт-Петербург, 2019. С. 334–337.

3. **Данилов В.В.**, Скирневский И.П., Гергет О.М. Метод поиска эффективной последовательности алгоритмов обработки медицинских данных при сегментации анатомических структур сердца // ГрафиКон 2017: Обработка и анализ биомедицинских изображений. Пермь, 2017. С. 258–263.

4. Манаков Р.А., Гергет О.М., **Данилов В.В.** Метод распознавания и сегментации дистального конца катетера на основе нейронных сетей // Молодёжь и современные информационные технологии: сборник трудов XV Международной научно-практической конференции студентов, аспирантов и молодых учёных. Томск: Издательство ТПУ, 2017. С. 380–381.

5. **Данилов В.В.**, Литвинов Р.Г., Гергет О.М. Анализ методов математического моделирования электрической активности сердца // Информационные технологии в науке, управлении, социальной сфере и медицине: сборник научных трудов III Международной научной конференции. Томск, 2016. С. 649–651.

Свидетельства о государственной регистрации и патент

1. Свидетельство о государственной регистрации программы для ЭВМ №2020613197 (RU); заявка №2020611881 от 25.02.2020, дата регистрации 11.03.2020; Бюл. №3 от 11.03.2020 //

Клышников К.Ю., Овчаренко Е.А., Скирневский И.П., **Данилов В.В.** Модели локализации стеноза на основе данных ангиографии.

2. Свидетельство о государственной регистрации программы для ЭВМ №2020612121 (RU); заявка №2020610938 от 03.02.2020, дата регистрации 17.02.2020; Бюл. №2 от 17.02.2020 // **Данилов В.В.**, Манаков Р.А., Скирневский И.П. Наложение медицинского инструмента на графические данные ультразвукового исследования.

3. Свидетельство о государственной регистрации программы для ЭВМ №2020611930 (RU); заявка №2020610927 от 03.02.2020, дата регистрации 12.02.2020; Бюл. №2 от 12.02.2020 // **Данилов В.В.**, Скирневский И.П., Манаков Р.А. Сегментация изображений на основе распространения динамически изменяемых суперпикселей.

4. Свидетельство о государственной регистрации программы для ЭВМ №2019664820 (RU); заявка №2019663014 от 22.10.2019, дата регистрации 13.11.2019; Бюл. № 11 от 13.11.2019 // **Данилов В.В.**, Кравченко А.А., Колпашиков Д.Ю., Лаптев Н.В., Манаков Р.А., Гергет О.М. Система автоматического тестирования гибких роботов.

5. Свидетельство о государственной регистрации программы для ЭВМ №2019664675 (RU); заявка №2019663095 от 16.10.2019, дата регистрации 12.11.2019; Бюл. №11 от 12.11.2019 // **Данилов В.В.**, Гергет О.М. Система локализации и сегментации хирургического инструмента и анатомических структур на основе машинного обучения.

6. Решение о выдаче патента на изобретение от 18.03.2020. Лабораторный стенд для оценки параметров гибких манипуляторов / Лаптев Н.В., Колпашиков Д.Ю., Гергет О.М., Манаков Р.А., Кравченко А.А., **Данилов В.В.**, Скирневский И.П. Заявка №2019127060 от 28.08.2019.