

Казахский Национальный Университет имени аль-Фараби

УДК 004(043)

**ТУРСЫНОВА АЖАР ТОЙЛЫБАЙҚЫЗЫ**

**Разработка системы Интернета вещей, оснащенной глубоким обучением,  
для диагностики инсульта**

8D07109 – Автоматизация и Internet of things

Диссертация на соискание степени Doctor of Philosophy (Ph.D.)

Отечественный научный консультант:  
Омаров Батырхан Султанович, PhD,  
доцент, Алматы, Казахстан

Зарубежный научный консультант:  
Октавиан Постолаче, PhD, профессор,  
Лиссабон, Португалия

Республика Казахстан

Алматы, 2024

## СОДЕРЖАНИЕ

<b>НОРМАТИВНЫЕ ССЫЛКИ.....</b>	<b>4</b>
<b>ОБОЗНАЧЕНИЯ И СОКРАЩЕНИЯ.....</b>	<b>5</b>
<b>ВВЕДЕНИЕ.....</b>	<b>8</b>
<b>1. ОБЗОР ЛИТЕРАТУРНЫХ ИСТОЧНИКОВ ДЛЯ ДИАГНОСТИКИ ИНСУЛЬТА.....</b>	<b>12</b>
<b>1.1 Патофизиология инсульта.....</b>	<b>инсульта</b>
.....Ошибка!	
.....Закладка	не
.....определена.	<b>12</b>
<b>1.2 Виды инсульта.....</b>	<b>14</b>
<b>1.3 Анализ современных подходов к прогнозированию инсульта с помощью искусственного интеллекта и Интернета медицинских вещей...18</b>	
<b>2. ПОДХОДЫ И СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ ДИАГНОСТИКИ ИНСУЛЬТА.....</b>	<b>26</b>
<b>2.1 Обзор методов машинного обучения и глубокого обучения.....27</b>	
<b>2.1.1 Обучение с учителем.....27</b>	
<b>2.1.2 Обучение без учителя.....30</b>	
<b>2.1.3 Обучение с подкреплением.....35</b>	
<b>2.1.4 Искусственная нейронная сеть.....41</b>	
<b>2.2 Глубокое обучение.....44</b>	
<b>2.2.1 Сверточная нейронная сеть.....45</b>	
<b>2.2.2 U-Net.....47</b>	
<b>2.3 Обнаружение инсульта.....48</b>	
<b>2.4 Классификация инсульта.....54</b>	
<b>2.5 Сегментация инсульта.....63</b>	
<b>3 МАТЕРИАЛЫ И МЕТОДЫ ДЛЯ ДИАГНОСТИКИ ИНСУЛЬТА....75</b>	
<b>3.1 Материалы с открытым исходным кодом для визуализации инсульта.....75</b>	
<b>3.2 Применение Интернета медицинских технологий для диагностики инсульта.....78</b>	
<b>3.3 Классификация мозговых инсультов с поддержкой глубокого обучения на изображениях компьютерной томографии.....82</b>	
<b>3.3.1 Наборы данных применяемые для классификация мозговых инсультов с применением глубокого обучения.....86</b>	
<b>3.3.2 Методы оценки модели для классификация мозговых инсультов.....87</b>	
<b>3.3.3 Основные математические формулы.....88</b>	
<b>3.4 Модель глубокой нейронной сети на основе UNet для сегментации очагов поражения головного мозга при инсульте на изображениях компьютерной томографии.....90</b>	
<b>3.4.1 Сегментация поражения головного мозга при инсульте с использованием изображений компьютерной томографии на основе глубокой модели U-Net с блоками ResNet.....92</b>	

<b>3.4.2 Наборы данных применяемые для модели глубокой нейронной сети на основе UNet.....</b>	<b>94</b>
<b>3.4.3 Методы оценки модели глубокой нейронной сети на основе UNet для сегментации изображении головного мозга.....</b>	<b>95</b>
<b>3.4.4 Основные математические формулы.....</b>	<b>96</b>
<b>4 РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ.....</b>	<b>98</b>
<b>4.1 Экспериментальные результаты применения Интернета медицинских вещей для диагностики инсульта.....</b>	<b>98</b>
<b>4.2 Результаты эксперимента модели для классификации мозговых инсультов с применением глубокого обучения.....</b>	<b>100</b>
<b>4.3 Результаты эксперимента модели глубокой нейронной сети на основе UNet для сегментации изображении головного мозга.....</b>	<b>104</b>
<b>4.4 Результаты эксперимента модели глубокой нейронной сети на основе UNet для сегментации изображении головного мозга с блоками ResNet..</b>	<b>108</b>
<b>ЗАКЛЮЧЕНИЕ.....</b>	<b>112</b>
<b>СПИСОК ЛИТЕРАТУРЫ.....</b>	<b>114</b>

## **НОРМАТИВНЫЕ ССЫЛКИ**

В данной диссертации использовались ссылки согласно следующим стандартам:

- Закон Республики Казахстан «О здоровье народа и системе здравоохранения» от 7.07.2020 г. № 360-VI ЗРК.
- Закон Республики Казахстан «О науке» от 18.02.2011 г. № 407-IV ЗРК.

## **ОБОЗНАЧЕНИЯ И СОКРАЩЕНИЯ**

IoT – Internet of things  
ИМВ (IoMT) – Интернет медицинских вещей (Internet of medical things)  
ГО (DL) – Глубокое обучение (Deep learning)  
CNN – Сверточные нейронные сети  
UNet- U образная сеть  
ResNet – Residual Network  
РХП (ROC) - Рабочие характеристики приемника  
МРТ – Магнитно резонанская томография  
КТ – Компьютерная томография  
ССЗ – Сердечнососудистые заболевания  
ИИ – Искусственный Интеллект  
ИЦГ - Интракраниальный геморрагический инсульт  
МКБ-10 - Международной классификации болезней 10-го пересмотра  
FSM - Функция модуля подобия  
CPGAN - Генеративной состязательной сети последовательного восприятия  
FLAIR - инверсия-восстановление  
EM - Алгоритм максимизации математического ожидания  
FODPSO - Оптимизация роя частиц Дарвина дробного порядка  
OCSP - Оксфордширский проект по борьбе с инсультом  
DWI - Диффузионно-взвешенная визуализация  
FCM - Нечеткие c-средние  
X-Net – X Network  
MFMF - Multi-feature map fusion network  
НКТ (NCCT)- Неконтрастная компьютерная томография  
MCA - Средняя мозговая артерия  
Mask R-CNN - Маскирующий области со сверточными нейронными сетями  
EHR - Электронная медицинская карта  
RL - Обучение с подкреплением  
ИНС - Искусственная нейронная сеть  
ЛР - Логистическая регрессия  
ММП - Метод максимального правдоподобия  
NB - Наивный байес  
DT - Дерево решений  
RF - Случайный лес  
AB – Adaboost  
SVM - Метод опорных векторов  
kNN - K- Ближайшие соседи  
НС – Нейронная сеть  
MLE - Оценка максимального правдоподобия  
PCA - Анализ основных компонентов  
BCs - Базовые компоненты  
MDP - Марковский процесс принятия решений

SDP - Последовательное решение  
TD - Временная разница  
SARSA - State-Action-Reward-State-Action  
ANNs - Искусственные нейронные сети  
ReLU - Rectified linear unit  
САПР - Автоматизированная диагностическая система  
ДВИ - Диффузионно-взвешенное изображение  
CNR- Отношение контрастности к шуму  
HU - Единицы Хаунсфилда  
PSO - Оптимизация роя частиц  
MMD - Минимальное среднее расстояние  
LPM - Карта вероятности повреждения  
MVI - Микроволновая визуализация  
TFE - Извлечение текстурных объектов  
GLCM - Матрица совпадений уровня серого  
UFL - Неконтролируемое обучение объектов  
ISLES - Очаговая сегментация ишемического инсульта  
DC - Кубический коэффициент  
RBFNN - Радиальная функциональная нейронная сеть  
MOGA - Многоцелевой генетический алгоритм  
ОИИ - Острый ишемический инсульт  
SLIC - Простая линейная итеративная кластеризация  
DICOM - Digital Imaging and Communications in Medicine  
GE - General Electric  
SISS - Сегментация подострого инсульта  
SPES - Оценки перфузии при наводнении  
CBF - Мозговой кровоток  
CBV - Объем мозговой крови  
CCMT - Сердечнососудистые заболевания головного мозга  
PACS - Синдром частичного переднего кровообращения  
LACS - Лакунарный синдром  
TACS - Общий инсульт переднего кровообращения  
ЭМТ - Электромагнитная томография  
ОИТ - Отделении интенсивной терапии  
DSS - Система поддержки принятия решений  
MTT - Среднее время прохождения  
OT - Сегментарное изображение  
Tmax - Функция остатков ткани  
TP - Истинные срабатывания  
FP - Ложные срабатывания  
TP - Истинно положительные результаты  
FN – Ложноотрицательные  
CW – Непрерывно-волновой  
OCA - Общая сонная артерия

ВСА - Внутренняя сонная артерия

АЦП - Аналого-цифровой преобразователь

## **ВВЕДЕНИЕ**

**Актуальность исследования.** Ишемический инсульт является наиболее распространенным цереброваскулярным заболеванием во всем мире и только в США составляет 87% всех инсультов. Он образуется при закупорке мозговой артерии, прерывая кровоток и в конечном итоге убивая клетки мозга. Эффективность возможных методов лечения в значительной степени зависит от времени, прошедшего с момента начала инсульта. Точное сегментирование очага инсульта (то есть пораженной области мозга) - очень утомительная задача, требующая изучения нескольких последовательностей МРТ и имеющая низкое согласие между наблюдателями. Инсульт может произойти в любом месте мозга с различными размерами, и его характеристики сильно варьируются. Ручная сегментация является золотым стандартом, но она непрактична в медицинской практике.

Несмотря на обнадеживающие данные о снижении заболеваемости инсультом, на глобальном уровне старение населения и накопление факторов риска способствуют увеличению пожизненного риска инсульта. Согласно данным The Global Burden of Disease 2016 Lifetime Risk of Stroke Collaborators, средний глобальный пожизненный риск инсульта увеличился с 22,8% в 1990 году до 24,9% в 2016 году, что является относительным увеличением на 8,9% после учета конкурирующего риска смерти от любой причины, отличной от инсульта. Рандомизированное исследование Менделя среди почти 500 000 китайских людей показало, что генетические маркеры, предсказывающие уровень холестерина липопротеидов низкой плотности, были непосредственно связаны с ишемическим инсультом и обратно связаны с внутримозговым кровоизлиянием, что дает причинные доказательства противоположного влияния уровня холестерина липопротеидов низкой плотности на 2 наиболее распространенных типа инсульта. Среди 81 714 женщин, участвовавших в проспективном когортном исследовании Women's Health Initiative, те, кто потреблял  $\geq 2$  искусственно подслащенных напитка ежедневно, в среднем имели повышенный риск всех инсультов (корректированная OR 1,23 [95% Ди 1,02–1,47]) и ишемического инсульта (корректированная OR 1,31 [95% Ди 1,06–1,63]) по сравнению с теми, кто потреблял  $<1$  искусственно подслащенный напиток еженедельно, после корректировки на демографию, анамнез ССЗ, факторы риска, индекс массы тела, поведение в отношении здоровья и общее качество диеты.

Компьютерная томография (КТ) и магнитно-резонансная томография (МРТ) являются наиболее распространенными методами, используемыми для диагностики инсульта. Хотя МРТ позволяет получить более качественные изображения, чем компьютерная томография [1], техника, необходимая для этой процедуры, доступна только в крупных учреждениях. Как правило, компьютерная томография является основным этапом диагностики инсульта, поскольку позволяет определить объем, тип и тяжесть поражения. Кроме того, компьютерная томография считается самой быстрой и экономичной

технологией диагностики инсульта [2]. В результате, учитывая необходимость быстрой диагностики, неоспорима первостепенная важность систем поддержки принятия решений, которые анализируют КТ-изображения для оказания помощи врачам в принятии медицинских решений [3].

Конечной целью использования методов визуализации при выявлении церебрального инсульта является как можно скорее установить диагноз и собрать точные данные о состоянии внутримозговой сосудистой сети и церебральной перфузии для принятия решений о лечении. В случае острого ишемического инсульта задержки в диагностике и лечении могут привести к серьезным последствиям для функций мозга, а также к повышенному риску смерти. Обоснованность медицинских вмешательств, таких как эндоваскулярное лечение, определяется локализацией поражения в заднем или переднем отделе кровообращения и периодом с момента возникновения нарушения [4-5]. Большинство процедур при лечении пациентов с симптомами требуют присутствия специалистов-людей. Обращение к медицинским экспертам - трудоемкий процесс, и эти специалисты не всегда могут быть доступны в каждом медицинском учреждении. Визуализирующие исследования, такие как КТ и МРТ, необходимы для быстрой диагностики поражений головного мозга при инсульте и определения того, какие участки паренхимы повреждены. Необходимы автоматизированные подходы к оценке мозгового инсульта, чтобы расширить возможности раннего лечения.

Традиционные методы автоматической идентификации и классификации церебральных инфарктов были разработаны с использованием набора рекомендаций по проектированию функций, предоставленных разработчиками алгоритмов после тщательного анализа клинических данных [6]. Из-за того, что некоторые аспекты потенциального мозгового инсульта скрыты и их трудно распознать при сканировании, традиционные методы автоматической классификации инсульта были затруднены из-за недостаточной сложности. С другой стороны, методы глубокого обучения позволяют извлекать визуальные атрибуты из обучающих выборок, в отличие от обычного машинного обучения [7]. Эти методы могут упростить моделирование церебральных инфарктов и устранить ограничения предыдущих подходов к глубокому обучению [8]. Выпуклые ядра используются сверточными нейронными сетями (CNNS) для извлечения определенных признаков из входного изображения, а также для решения различных задач категоризации изображений [9].

Современные приложения искусственного интеллекта предназначены для того, чтобы помочь людям решать самые разные проблемы. CNN - это одна из развивающихся подкатегорий глубокого обучения, которая в настоящее время широко используется в нейровизуализации [10]. Методы глубокого обучения и использование CNN оцениваются как стратегия диагностики острых ишемических инсультов. В последнее время интеллектуальный анализ данных и глубокое обучение стали самыми популярными темами среди научного сообщества, которые дают удивительные результаты в робототехнике, распознавании изображений и искусственном интеллекте (ИИ).

Нейронные сети процветают в обработке неструктурированных данных, особенно изображений, текста, аудио и речи. Сверточные нейронные сети (CNN) лучше всего работают для таких неструктурированных данных.

Параллельно с этим растущее значение Интернета медицинских услуг (IoMT) начало изменять ландшафт здравоохранения [11]. IoMT, сеть взаимосвязанных медицинских устройств, способных взаимодействовать друг с другом через Интернет, обеспечивает обмен данными в режиме реального времени, удаленный мониторинг пациентов и мгновенное предоставление медицинских услуг [12]. В контексте лечения инсульта IoMT может революционизировать способы сбора, обмена и использования медицинских данных, значительно сократив время от появления симптомов до начала лечения [13].

Исследование методов диагностики инсульта с помощью Интернета медицинских вещей (IoMT) и глубокого обучения для анализа медицинских изображений обладает значительной актуальностью, учитывая высокую распространенность инсультов как одной из ведущих причин смертности и инвалидности на глобальном уровне. Эффективное раннее обнаружение инсульта может значительно улучшить исходы для пациентов, минимизируя последствия и повышая шансы на успешное вмешательство. В этом контексте, использование IoMT для мониторинга таких показателей, как скорость кровотока через сонные артерии, предоставляет ценные данные для своевременной диагностики. Кроме того, применение алгоритмов глубокого обучения к анализу КТ изображений мозга способствует значительному улучшению точности диагностических процедур, позволяя распознавать сложные паттерны, которые могут быть неочевидны для человеческого глаза. Такие технологии не только способствуют развитию персонализированных подходов к лечению, но и могут значительно снизить затраты на здравоохранение за счет уменьшения нужды в длительной реабилитации и уходе. Таким образом, развитие и интеграция передовых технологических решений в области диагностики инсульта становится ключевым направлением для улучшения качества и доступности медицинской помощи на современном этапе.

**Объект исследования:** являются КТ изображения головного мозга, кровоток в сонной артерии.

**Предмет исследования:** выступают ультразвуковой датчик для измерения скорости кровотока в сонной артерии, алгоритмы глубокого обучения для классификации и сегментации очагов инсульта в изображениях головного мозга.

**Целью** работы является построение комплексной системы автоматической диагностики признаков инсульта с использованием Интернета медицинских вещей и моделей глубокого обучения в изображениях головного мозга.

#### **Методы исследования:**

- Моделирование в среде proteus схематической части IoMT.

- Методы обработки изображений.

Методы глубокого обучения.

### **Новизна**

- Разработана IoMT устройство для обнаружения первых признаков инсульта по скорости кровотока в сонной артерии.
- Разработана модель глубокой нейронной сети для классификации инсульта с малым набором данных.
- Разработана глубокая модель на основе Unet для сегментации инсульта по изображениям головного мозга с ограниченным количеством данных.

Практическая значимость заключается в применении комплексной системы для диагностики инсульта с применением IoMT устройство для обнаружения первых признаков инсульта по скорости кровотока в сонной артерии и моделей глубокого обучения для классификации и сегментации изображений мозга. В состав IoMT устройство входят: CW(непрерывно-волновой) ультразвуковой датчик, микроконтроллер stmf32f401, одноплатный компьютер raspberry pi 4 model b. Модели глубокой нейронной сети для классификации и сегментации инсульта имеют возможности работы с малым набором данных.

**Задачи, поставленные для достижения цели исследовательской работы:**

- Исследование методов диагностики инсульта используя Интернета медицинских вещей.
- Анализ скорости кровотока в сонной артерии.
- Разработка прототипа Интернета медицинских вещей для диагностики инсульта по скорости кровотока в сонной артерии.
- Анализ моделей глубокого обучения в задачах классификации инсульта и сегментации очагов инсульта по изображениям головного мозга.
- Разработка моделей глубокого обучения для классификации и сегментации очагов инсульта по изображениям головного мозга.
- Оценка эффективности моделей глубокого обучения.

### **Положения выносимые на защиту**

- Построена комплексная система диагностики инсульта на основе Интернета медицинских вещей и моделей глубокого обучения.
- Разработана модель глубокого обучения на основе CNN для классификации изображений головного мозга с инсультом.
- Разработана модель для сегментации очага инсульта по 3D-изображениям головного мозга на основе модификации архитектуры U-Net.

Основные положения и результаты работы доложены на:

16-й Международной конференции «Компьютерная электроника и вычисления (ICECCO) 2021» 25-26 ноября 2021 года, в Казахстанском университете

Сулеймана Демиреля; 2021 - 11-й Международной конференции «Облачные вычисления, наука о данных и инженерия» 28-29 января 2021 года, г. Нойда, Уттар-Прадеш, Индия.

**Публикации.** Теме диссертации посвящены 8 научных работ, в том числе 5 – в научных журналах, входящих в базу данных Scopus и Web of Science, 2 – в материалах международных конференций, 1 патент РК.

Первая глава посвящена обзору литературных источников для диагностики инсульта, анализу современных подходов к прогнозированию инсульта с помощью искусственного интеллекта и Интернета медицинских вещей. Также рассматриваются виды и патофизиологии инсульта.

Во второй главе описываются подходы и системы поддержки принятия решений для диагностики инсульта. Даются обзоры методам машинного обучения и глубокого обучения. Приводятся три вида диагностики инсульта, а именно, определение, классификация и сегментация.

Третья глава рассматривает используемые материалы и применяемые методы для диагностики инсульта. Предлагаются модели и архитектуры для решения задач классификации и сегментации инсульта по изображениям головного мозга, основные методы для улучшения качеств и работоспособности моделей. Определены данные для работы с моделями, а также ИоМТоборудование.

Четвертая глава посвящена результатам исследования. Получены экспериментальные результаты применения Интернета медицинских вещей для диагностики инсульта, результаты эксперимента модели для классификации мозговых инсультов с применением глубокого обучения, результаты эксперимента модели глубокой нейронной сети на основе UNet и UNet с блоками ResNet для сегментации изображений головного мозга. Определяются оценки эффективности разработанных моделей глубокого обучения.

## 1. ОБЗОР ЛИТЕРАТУРНЫХ ИСТОЧНИКОВ ДЛЯ ДИАГНОСТИКИ ИНСУЛЬТА

### 1.1 Патофизиология инсульта

Инсульт - это клинический синдром церебральной недостаточности, длительность которого составляет 24 часа без видимой причины, кроме сосудистой. В развитых странах около 75-80% случаев инсульта обусловлены церебральной ишемией, а 10-15% - церебральным кровоизлиянием. Диагноз инсульта может быть точно и полностью установлен только специалистом на основе клинических данных [7].

#### *Ишемический инсульт.*

Сложности, свойственные патофизиологическим путям инсульта, многочисленны, хотя существует множество сходств и различий между ишемическим и геморрагическим инсультом. Ишемический инсульт инициирует последовательность событий, происходящих в начале церебральной ишемии, называемую ишемическим каскадом (рис. 1). Общее и точное время каждого события различается от других и зависит от множества

переменных, таких как размер инфаркта, начало и продолжительность ишемии, а также эффективность реперфузии. Ишемические события начинаются с постепенной или внезапной церебральной гипоперфузии и включают в себя клеточную биоэнергетическую недостаточность, эксцитотоксичность, оксидативный стресс, дисфункцию гематоэнцефалической барьера, повреждение микрососудов, активацию гемостаза, воспаление и, в конечном итоге, некроз нейрональных, глиальных и эндотелиальных клеток. Нарушение гематоэнцефалической барьера при ишемическом инсульте происходит в два этапа и зависит от агрессивности и реакции организма на реперфузию. В течение первых 24 часов после ишемического инсульта происходит увеличение проницаемости гематоэнцефалической барьера, а дополнительные повреждения наступают через 48-72 часа после инфаркта [8-9].

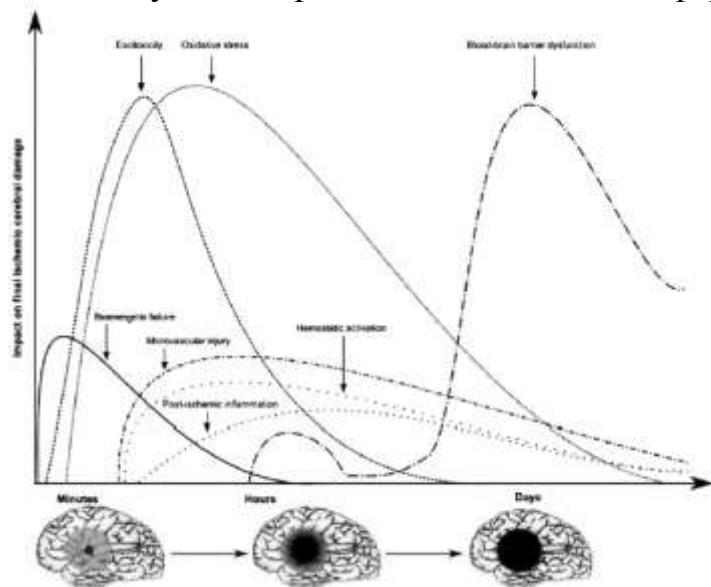


Рисунок 1.1 Временные события в ишемическом каскаде [14]

Основной причиной интрацеребрального геморрагического инсульта до сих пор считается хроническая гипертензия, вызывающая ослабление сосудов, и, несмотря на разные точки зрения, не отмечено значительного увеличения распространенности ИЦГ, даже при увеличении использования антикоагулянтов. Начало симптомов при ИЦГ также может быть временным или постепенным, а клинические результаты в значительной степени зависят от объема и расширения гематомы. В течение первых нескольких часов после ИЦГ возникают различные степени отека, приводящего к отягиванию сгустка и высвобождению осмотически активных белков в окружающие ткани [10] [15]. Через 2-3 дня начинается активная фаза коагуляционного каскада, сопровождающаяся синтезом тромбина и воспалительной реакцией. Также возникает токсичность нейронального гемоглобина и лизис эритроцитов через несколько дней после начального события ИЦГ. Проблемы, связанные с поиском биомаркера для геморрагического инсульта, связаны с отсроченным разрушением гематоэнцефалической барьера, которая остается неповрежденной для крупных молекул в течение нескольких часов после геморрагического инсульта. Только после серьезного увеличения объема

гематомы (в среднем через 8-12 часов) проницаемость гематоэнцефалической барьеры становится достаточно значительной для измерения белков, специфичных для мозга. Сложность и разнообразие типов тканей мозга, в сочетании с ограниченными знаниями о полной физиологии головного мозга, способствуют отсутствию конкретных биомаркеров для инсульта.

### *Геморрагический инсульт*

Геморрагический инсульт развивается у пациентов с высоким артериальным давлением, атеросклерозом сосудов головного мозга, кровеносными заболеваниями, а также при наличии врожденных и приобретенных сосудистых аневризм, васкулита и опухолей головного мозга [16]. Также этот тип инсульта может развиться в процессе лечения антикоагулянтами и тромболитическими препаратами [17].

Паренхиматозное кровоизлияние присуще артериальной гипертензии, которая приводит к ослаблению эндотелия капилляров в мозге, образованию микроаневризм, при разрыве которых происходит кровоизлияние в вещество мозга. Впоследствии образуется гематома, размер которой увеличивается за несколько минут или часов. При артериальной гипертензии гематомы чаще всего формируются в глубоких частях мозга в области капсулы, где находятся нервные волокна, соединяющие моторные и сенсорные центры коры головного мозга с мозжечком и спинным мозгом.

Также этимологическим фактором интрацеребральных кровоизлияний может быть фон врожденных аномалий сосудов, опухолей и васкулита, а также применение тромболитиков и антикоагулянтов. У пожилых людей из-за наличия амилоидной ангиопатии часто развиваются лобарные кровоизлияния, которые возникают при врожденных аномалиях, таких как артериовенозная конформация.

С увеличением размера гематомы и развитием рефокального мозгового отека увеличивается внутричерепное давление, развивается механическое смещение соседних структур мозга и сжатие срединных частей мозга в нижнюю часть задней черепной ямки, что вызывает сдавление ствола. Это приводит к нарушению дыхания и гемодинамики, а в некоторых случаях к смерти. Подарахноидальное кровоизлияние локализуется в подмозговом пространстве головного мозга. Оно часто развивается при нарушении целостности внутричерепного аневризмы и встречается в 80% случаев среди подарахноидальных кровоизлияний. Этот тип геморрагического инсульта не так часто возникает вследствие травм, разделения внутричерепной артерии, геморрагической диатезы [18].

## **1.2 Виды инсульта**

Внезапное нарушение сердечно-сосудистой системы, приводящее к появлению острых неврологических симптомов, определяется медицинским термином «инсульт» [19]. Согласно Международной классификации болезней 10-го пересмотра (МКБ-10), эта болезнь относится к разделу «заболевания цереброваскулярной системы» [20]. В эту категорию входят патологии,

вызванные изменениями в сосудах, питающих мозг (церебральные). В зависимости от клинической картины инсульта, его делят на типы, кодированные соответствующими символами (коды I60-I64). Этиология болезни основана на резком нарушении кровообращения в мозге, которое происходит вследствие сужения, разрыва или блокировки сосудов. В отсутствие поступления кислорода и жизненно важных питательных веществ, которые должны поступать в кровоток, начинаются необратимые изменения в клетках мозга. Результатом патологических изменений является развитие неврологического дефицита, который либо регрессирует со временем (более 24 часов), либо приводит к смерти пациента. В связи с высокой смертностью от цереброваскулярных заболеваний, изучение их этиологии и патогенеза является важным направлением неврологии [21].

Факторы риска - это то, что увеличивает наши шансы на заболевание. Они делятся на два типа: модифицируемые и немодифицируемые факторы риска для инсульта. Модифицируемые факторы риска включают возраст, пол и наследственность или семейную историю. С возрастом риск инсульта увеличивается; мужчины чаще подвержены другим факторам риска. Семейная история включает в себя историю сердечного приступа и инсульта [22]. Затем важным фактором риска является артериальная гипертензия. Затем, немодифицируемые факторы риска включают курение, гипертонию, высокое артериальное давление, сахарный диабет, отсутствие физической активности, высокий холестерин в крови или алкоголь. Повышенное артериальное давление может привести к повреждению сосудов, в основном к инсульту. Курение повышает артериальное давление и снижает содержание кислорода в крови. Токсичные вещества оседают в легких; эти вещества вредны для сосудов. Это увеличивает вероятность образования тромбов. Избыточный вес - это увеличение жира в организме, что может способствовать повышенному артериальному давлению и высокому холестерину. Алкоголь - это ежедневное употребление алкоголя, которое может поднимать артериальное давление до высокого уровня. В этом случае увеличивается риск развития геморрагического инсульта обоих типов и ишемического инсульта [23-25].

Ишемический инсульт в первую очередь по распространенности среди всех видов острого цереброваскулярного происшествия - это ишемическое повреждение тканей мозга. Причиной патологии является резкое снижение кровотока к тканям мозга, которое происходит из-за блокировки или стеноза (сужения) сосудов [26]. Большинство случаев вызывается артериальной или сердечной патологией, эндокринными нарушениями и воздействием токсичных веществ (табак, наркотики, алкоголь) [23-25]. Ишемия или гибель клеточных тканей может произойти в любой части мозга, локализация определяется пораженным артериальным бассейном - внутренней или основной сонной артерией, позвоночной или церебральной (средней, передней, задней) артериями. Выделяют следующие типы инсульта в зависимости от условий образования очага размягчения тканей мозга (таблица 1.1 Классификация инсульта. Эта таблица содержит информацию о различных типах инсультов, их

условностях, особенностях развития и размере поражения, характерном для каждого типа):

Таблица 1.1: Классификация инсульта.

Тип	Условности	Особенности развития	Размер поражения
Атеротромботический	Атеросклероз сосудов головного мозга	Постепенное увеличение симптомов, часто предшествующих проявлениям болезни (переходные ишемические атаки)	Переменный
Кардиоэмболический	Тромбоэмболия сосудов головного мозга или других органов	Внезапное начало, тяжелые неврологические симптомы, характеризуется наличием экстравазата (кровь вытекает в окружающие ткани)	Средний, большой
Лакунарный	Высокое артериальное давление, гипертония, повреждение мелких артерий	Постепенное увеличение фокусных симптомов при отсутствии общих симптомов головного мозга, очаги локализованы в субкортикальных структурах	Не превышает 1,5 см
Гемодинамический	Артериальная гипотензия, атеросклероз, васкулярные аномалии	Внезапное или постепенное начало в состоянии покоя или бодрствования, очаги локализованы в кортикалной или перивентрикулярной зоне	Переменный
Реологический (Гемореологическое окклюзия)	Патология системы свертывания крови (повышенная свертываемость или усиление способности тромбоцитов слипаться) при отсутствии установленных гематологических или сосудистых заболеваний	Слабо выраженные неврологические признаки при наличии значительных нарушений гемореологии	До 1,5 см <sup>3</sup>

С геморрагическим инсультом кровь в мозг поступает реже, чем при ишемии, но последствия этого типа болезни более серьезны, и прогноз лечения не так благоприятен. Механизм развития патологии заключается в том, что мозговые ткани раздавливаются гематомой, образованной из крови, вышедшей из сосудистого русла. Отток жидкой соединительной ткани происходит из-за нарушения церебрального кровообращения, что приводит либо к разрыву сосудов, либо к снижению их тонуса и увеличению проницаемости сосудистых стенок [27]. Большинство геморрагических инсультов связаны с последствиями артериальной гипертензии в виде паралича и спазма артерий, питающих мозг. Особенностью этого типа патологии является ее быстрое развитие, которое происходит в бодрствующем состоянии человека и вызвано стрессом [28]. Причины болезни в 2-15% случаев остаются неясными, в то время как у 25% пациентов приступ развивается на фоне острого цереброваскулярного происшествия неизвестной этиологии [29]. Во всех остальных случаях устанавливается связь между патологией и следующими факторами:

артериальная гипертензия; диабет; фибрилляция предсердий или аритмия синдрома сикловидных клеток; нарушение функционирования элементов сердечно-сосудистой системы; курение; ожирение; недостаток физической активности; высокий холестерин [23-25].

В зависимости от местоположения гематомы существует несколько типов этого типа сердечно-сосудистого происшествия. Точно определить тип геморрагического инсульта можно только по результатам диагностики. Характерные проявления всех подвидов включают резкие приступы головной боли, судорожный синдром, потерю сознания [27]. Острый геморрагический цереброваскулярный инцидент делится на: паренхиматозный - отток крови в ткани мозга (паренхима); внутрижелудочковый - образование гематомы в полостях, заполненных мозговым спинномозговым жидкостью (желудочки); субдуральное кровоизлияние в области выше твердой мозговой оболочки; экстрадуральное - образование гематомы под твердой мозговой оболочкой; смешанное - редкое явление, при котором происходят множественные кровоизлияния сразу в нескольких зонах. Отдельным типом геморрагической болезни аневризматического происхождения (в результате разрыва образования кисты на стенках сосуда) является субарахноидальное кровоизлияние, при котором кровь выливается в подарахноидальное пространство (полость, заполненную мозговой спинномозговой жидкостью). Самые распространенные причины этого типа патологии - травматические повреждения головного мозга, наркомания кокаином, а также употребление алкоголя в очень больших количествах, что даже возможно от единичной дозы [28].

Один из типов сосудистой катастрофы, частота которой составляет менее 1% от всех зарегистрированных случаев цереброваскулярного происшествия, - это цереброспинальный инсульт [30]. Эта патология развивается вследствие повреждения спинного мозга, что приводит к ухудшению или полному прекращению кровотока через спинные артерии. Атеросклероз, эмболия и хирургическое вмешательство (в случае сжатия спинных вен или артерий) являются основными причинами патологических процессов. В зависимости от этиологии нарушений кровообращения в спинном мозге выделяют ишемический (миелоидная ишемия) и геморрагический (гематомиеля) типы этой болезни [31]. Гематомиеля - это редкое, но очень опасное по своим последствиям и проявлениям явление. Вливание крови в мозговую спинномозговую жидкость приводит к быстрому развитию острых симптомов и параличу одной или нескольких конечностей. При геморрагии в подарахноидальное пространство спинного мозга (гемоторакс) признаки, указывающие на изменение состава мозговой спинномозговой жидкости, могут отсутствовать на ранних стадиях, что затрудняет диагностику. Прогноз лечения зависит от размеров эпидуральных гематом (образующихся при вливании крови в толщу спинного мозга) - небольшие редко приводят к осложнениям, большие часто сопровождаются остаточными эффектами [32]. Клиническая картина ишемического поражения спинных структур зависит от локализации

очага некроза (таблица 2. Локализация очага некроза при цереброспинальном инсульте и соответствующих клинических симптомах):

Таблица 1.2: Локализация очага некроза при цереброспинальном инсульте и соответствующих клинических симптомах

Локализация очага некроза	Клинические симптомы
Верхние участки передней спинномозговой артерии	Двигательные нарушения всех конечностей, сниженная чувствительность к боли и изменениям температуры.
Передняя артерия в области пересечения пирамид	Частичный паралич конечностей - руки со стороны поражения и ноги с противоположной стороны.
Верхние сегменты шейного отдела в одной половине	Парез парных конечностей, расположенных по стороне поражения, потеря чувствительности половины тела с противоположной стороны.
Первые и вторые сегменты шейного отдела	Выступ головы, вялый паралич.
Крайние зоны передних или боковых веревок	Незначительный парез конечностей, небольшое уменьшение поверхностной чувствительности.
Средние сегменты грудного отдела	Задержка мочеиспускания, ухудшение двигательной функции, температурная и болевая чувствительность ног.
Нижний дополнительный позвоночно-спинной артерии	Паралич мышц голеностопа, опускание стопы.
Нижние сакральные области	Недержание мочи и кала.
Задняя спинномозговая артерия	Отсутствие чувствительности в конечностях.

### 1.3 Анализ современных подходов к прогнозированию инсульта с помощью искусственного интеллекта и Интернета медицинских вещей

Анализ медицинских изображений в 1970-1990-е годы проводился на основе последовательной низкоуровневой обработки пикселей и математического моделирования [33].

Анализ изображений также нашел свое место в медицине. Сегментация органов по медицинским данным позволяет получить информацию о форме исследуемого объекта, его размере и площади. Перед каждым методом сегментации стоит задача определения контуров/границ или участков исследуемого изображения.

Несмотря на то, что появились форматы 3D-изображений, многие исследования и вычисления выполняются быстрее и намного проще с использованием 2D-форматов при сегментировании сверточных нейронных сетей КТ и МРТ. Игнорируя 2D-модель CNN для получения 3D-информации, в то время как 3D-модели CNN требуют мощных вычислительных ресурсов, было целесообразно предложить архитектуру под названием dimension-fusion-UNet (D-UNet), которая обеспечивает комбинацию 2D и 3D свертки на этапе кодирования [34]. Для преодоления вычислительной нагрузки, связанной с обработкой 3D-медицинских изображений, требуется эффективное устранение ложноположительных результатов. В этом смысле использование трехмерного полностью связанного условного поля оказывает влияние на

мягкую сегментацию сети после обработки. Этот метод, а также архитектура, которая имеет 11-слойную глубокую трехмерную сверточную нейронную сеть с двойным путем, предназначены для решения сложных задач сегментации поражений головного мозга, где одним из них является ишемический инсульт [35].

Правильно применяемые методы и алгоритмы машинного обучения при анализе медицинских изображений не всегда играют ключевую роль, но отсутствие достаточного количества маркированных данных ограничивает прогресс исследований в этой области. Применение структуры расширения данных с использованием условной генеративной состязательной сети (cGAN) и сверточной нейронной сети с управлением сегментацией позволяет генерировать изображения мозга из специально модифицированных масок повреждений, а также функцию модуля подобия (FSM) для облегчения процесса обучения, что приводит к лучшей сегментации повреждения [36]. Автоматизированный метод, основанный на t-тесте Кроуфорда-Хауэлла и сравнении изображений головного мозга после инсульта со здоровыми, обеспечил высокую чувствительность, которая легко поддается расчету и интерпретации. Этот подход не требует больших вычислительных мощностей и памяти и может быть реализован на настольной рабочей станции и интегрирован в рутинную клиническую диагностику [37].

При сегментировании медицинских изображений также существуют различия между точностью классификации и правильностью сегментации. Применение глубокой сверточной нейронной сети и каскадной структуры, которая устанавливает комбинированную структуру обучения с использованием условного случайного поля для более эффективной модели с прямыми зависимостями между тегами пространственного замыкания, используемыми при обработке после сегментации, обеспечивая при этом точность сегментации, правильную глубину сети и количество соединений. [38]. Сегментация очагов острого ишемического инсульта с использованием мультимодальной МРТ на U-образной архитектуре структуры со встроенным остаточным блоком в сети, облегчая проблему, связанную с деградацией, показала хорошую производительность как в одномодальном, так и в мультимодальном режиме [39]. В целом, острое ишемическое поражение проявляется в автоматической сегментации состояния после инсульта при диффузионно-взвешенной МР-томографии с использованием архитектуры CNNs, которая использует в одной части пару деконверсионных сетей сети EDD для устранения потенциальных ложноположительных результатов, а во второй части многомасштабную сверточную сеть с оценками меток, направленную на оценивание поражения, дают очень хорошие результаты [40]. Благодаря своей скорости, доступности и неотрицательным характеристикам КТ-перфузия была использована для сортировки пациентов с ишемическим инсультом. Параметры перфузии также могут быть рассчитаны на основе данных КТР. Автоматическая сегментация для определения местоположения ядра пораженной области на основе генеративной модели, состоящей из

экстрактора, генератора и ментора сегментов, и использование, кроме того, новой функции потери площади пикселя и перекрестной энтропии помогут определить и улучшить этот процесс [41].

Автоматизация процесса размеченных вручную масок, благодаря которой методы глубокого обучения демонстрируют впечатляющую производительность в задачах сегментации, с использованием новой управляемой генеративной состязательной сети последовательного восприятия (CPGAN), с модулем подключения подобия для сбора информации о многомасштабных функциях и с вспомогательной сетью упрощает дорогостоящий и трудоемкий процесс [42]. В качестве другого примера рассмотрим один из новых методов сегментации на основе МРТ с восстановлением инверсии (FLAIR) с помощью разбавленной жидкости, где в качестве начальной сегментации используется байесовский метод, основанный на текстурах Габора, затем используется марковская модель случайного поля [43]. Сегментация с использованием алгоритма максимизации математического ожидания (EM) и метода оптимизации роя частиц Дарвина дробного порядка (FODPSO) в соответствии со схемой Оксфордширского проекта по борьбе с инсультом (OCSP) были предложены в [44] для повышения точности определения пораженной области мозга. Получение подробной информации о контрастировании мягких тканей в органе головного мозга имеет преимущество диффузионно-взвешенной визуализации. Сегментация методом DWI с использованием нечетких с-средних (FCM) и активных контуров для разделения спинномозговой жидкости (ликвора) при гипointенсивном поражении потенциально может быть использована для сегментации изображений поражений головного мозга с помощью DWI [45]. Решение таких проблем, как неподготовленность к работе с большим количеством параметров, при использовании методов извлечения контекстной информации и для определения долгосрочных зависимостей, было предложено в [46], с помощью глубокой совместной свертки на основе X-Net, разработки нелокальной операции или модуля подобия признаков (FSM), обеспечивая плотное извлечение контекстуальной информации, что в результате способствует лучшей сегментации.

Другой из неортодоксальных методов исследования с аннотацией к меткам был предложен авторами в [47], используя комбинации из множества слабо помеченных и нескольких полностью помеченных объектов в сети multi-feature map fusion network (MFMF) с парой ветвей, где одна часть использовалась для обучения ветви классификации, а другая - для получения дополнительной информации. другое - для настройки ветви сегментации. Авторы в работе [48] предлагают свой собственный метод, называемый Конвей-анализом симметрии глубоких поражений и МРТ-сканированием, автоматической сегментацией хронических поражений после инсульта. Использование симметричных вокселов в их 8-слойной 3D-архитектуре приводит к хорошей производительности системы. Использование компьютерной томографии для выявления первых признаков ишемического

инфаркта невозможна. Так, в работе [49] предложен метод выявления ишемии, основанный на контрастном усилении компьютерной томографии. Этот метод состоит из трех этапов: предварительной обработки, улучшения изображения и классификации.

Мы исследовали некоторые из наиболее популярных методов машинного обучения для классификации инсультов с использованием изображений компьютерной томографии и рассмотрели САПР-системы для диагностики инсультов.

Очень важно как можно скорее выявить ранние ишемические изменения, вызванные острым ишемическим инсультом, на изображениях неконтрастной компьютерной томографии (НКТ), поскольку решение о необходимости введения тканевого активатора плазминогена должно быть принято в течение 4-5 часов, начиная с появления первичных симптомов [50]. С другой стороны, результаты компьютерной томографии, связанные с ранними ишемическими изменениями, являются слабыми и их трудно обнаружить на томограммах. Например, Akasaka et al. сообщалось, что когда МРТ использовалась в качестве основного стандарта диагностики ишемического инсульта, средняя чувствительность диагностики инсульта по данным неконтрастной компьютерной томографии головы (NCCT) составила 26,5% у 14 рентгенологов [51]. Таким образом, автоматизированная система, помогающая медицинским экспертам в диагностике острого ишемического инсульта по томограммам, может быть полезна в клинических условиях.

В настоящее время специалисты по информатике оказывают помощь врачам и медицинским экспертам различными способами, включая использование вычислительных методов для обработки цифровых медицинских изображений [52-54]. Чанг и соавт. [53] разработали метод идентификации острого ишемического инсульта на КТ-снимках, который позволяет классифицировать изображения с инсультом и без него с точностью 81%. Ученые использовали ранжирующие признаки, полученные на основе предварительно обработанных КТ-изображений, чтобы определить 23 релевантных признака для идентификации инсульта, восемь из которых были использованы для построения прогностических моделей. Гоцин и др. [54] разработали метод классификации областей асимметричного изображения для выявления признаков ишемического инсульта на неконтрастных КТ-изображениях с точностью 76,84% в 108 случаях инсульта, которые были пропущены профессиональными рентгенологами [55].

Чтобы обойти ограничения на данные, в многочисленных публикациях, упомянутых в разделе «Ссылки», использовались хорошо известные подходы к глубокому обучению и добавлялась модель обучения с переносом данных путем повторного использования предварительно обученных весовых коэффициентов сети. Шинохара и соавт. [56] использовали набор данных с 22 томограммами и стратегию обучения переносу на основе патчей в сети Xception [57] для выявления симптомов гипертрофии средней мозговой артерии (МСА). Чтобы классифицировать типы инсульта на кровоизлияние и ишемию, Фонг и

соавт. [58] и Ло и соавт. [59] провели сравнительный анализ двумерных моделей CNN. В другом исследовании была предложена перспектива использования трансферного обучения в качестве представления признаков с дескрипторами признаков, полученными путем удаления связанных слоев. Для извлечения признаков Дурадо и др. [60] использовали различные архитектуры глубокого обучения и сравнили эффективность классификации и извлеченных признаков с использованием различных методов машинного обучения. Сью и др. [61] в своем всестороннем исследовании сравнили дескрипторы признаков, полученные с использованием ResNet, с кобалютными матрицами уровня Грея и моментами Hu [62].

Субуди и др. [63] использовали модель случайной лесной классификации для разработки нового подхода к сегментации и классификации случаев инсульта на основе данных МРТ. Предложенная модель помогла достичь 93,4-процентной точности при обработке 192 изображений головного мозга. Однако следует отметить, что в исследовании не приводится никакого описания набора данных, например, где и как они были собраны. Ортис-Рамон и соавт. [64] также сосредоточились на данных ФМРТ, предложив подход к извлечению структурных особенностей, чтобы определить, является ли инсульт лакунарным или кортикальным. Для их исследования в данной публикации авторы применили различные методики, предложенные разными учеными, ссылки на которые можно найти в [65]. По словам исследователей, основным недостатком их исследования считается невозможность интегрировать данные об инсульте и старении для анализа изображений, показывающих недавние кортикальные или лакунарные инсульты. С другой стороны, методы нормализации изображений могут помочь преодолеть эту проблему за счет улучшения качества изображения.

Для моделирования системы под названием DeepRadiology-Net было использовано 24 000 неконтрастных компьютерных томографических маркеров головного мозга (NCCT). Ожидается, что модель сможет идентифицировать 30 различных признаков КТ головного мозга. Классам были присвоены метки низкого, среднего и высокого риска с использованием иерархической функции потерь. На дизайн повлияла GoogLeNet, и результаты были сравнены с другими аналогичными структурами. Кроме того, были отмечены некоторые поразительные решения с использованием двумерной модели CNN на основе патчей [66].

Хан и соавт. [67] предложили подход глубокого обучения для классификации инсульта и сегментации очагов поражения на КТ-изображениях, основанный на использовании глубоких моделей [68]. Эффективность подхода была доказана достижением 97%-ной точности при категоризации данных о легких и 97%-ном коэффициента Dice при сегментации, что подтверждает перспективность системы в области таргетинга. Однако следует отметить, что методология не смогла эффективно сегментировать определенные области легких, что может быть связано с обобщением модели. Соуза и др. [69] использовали модель маскирующих

областей со сверточными нейронными сетями (Mask R-CNN) в сочетании с контролируемыми и неконтролируемыми подходами в качестве стратегий тонкой настройки для сегментирования областей легких на 39 КТ-изображениях. В результате наилучший метод показал точность в 95%. Стоит отметить, что стратегия [68] была протестирована всего на нескольких тестах. Очень важно использовать более общий метод сбора данных, даже если используемые подходы основаны исключительно на фотографиях для проведения процедуры [70].

Тайбахш и др. [71] выразили обеспокоенность по поводу эффективности методов тонкой настройки в подходах к глубокому обучению. Исследователи сравнили две модели Deep CNN для сегментации медицинских изображений, связанных с радиологией, кардиологией и гастроэнтерологией, одна из которых была обучена на базовом уровне, а другая - с тонкой настройкой. По словам авторов, в большинстве случаев система глубокого обучения CNN с тонкой настройкой превосходила или, в худшем случае, соответствовала системе CNN, обученной без тонкой настройки. Таким образом, эффективность метода была продемонстрирована. Извлечение патчей из 2D-изображений было еще одним приемлемым решением для увеличения объема обучающих данных [72].

Слияние глубокого обучения (DL) и Интернета медицинских услуг (IoMT) знаменует собой захватывающую связь двух доминирующих тем в последних исследованиях технологий здравоохранения. Чтобы оценить новизну и ценность нашей работы, важно понимать более широкий спектр этих областей, о которых будет рассказано в этом разделе.

Многочисленные исследования в области DL продемонстрировали его потенциал для анализа изображений в различных областях медицины. Сверточная нейронная сеть (CNN), класс искусственных нейронных сетей с глубокой передачей данных, сыграла особую роль в задачах классификации изображений [73]. Появление DL активизировало область анализа медицинских изображений, расширив границы того, что было возможно ранее.

Крижевски и др. (2012) впервые применили DL в распознавании изображений, разработав модель CNN, известную как AlexNet, которая значительно превзошла другие модели в крупномасштабной задаче визуального распознавания ImageNet [74]. Эта плодотворная работа заложила основу для последующего изучения DL для медицинской визуализации. Например, Эстева и др. (2017) использовали CNNS для диагностики рака кожи по клиническим изображениям, продемонстрировав эффективность, сравнимую с результатами дерматологов [75]. Далее, Гульшан и др. (2016) использовали модель DL для выявления диабетической ретинопатии и макулярного отека на фотографиях глазного дна сетчатки, что соответствует или превосходит показатели людей, оценивающих инсульт [76].

Когда дело доходит до диагностики и прогнозирования инсульта, DL доказала свою ценность. Хаваи и соавт. (2017) использовали метод, основанный на DL, для сегментации опухолей головного мозга, подчеркивая потенциал DL для анализа сложных изображений головного мозга [77]. Zhang и соавт. (2020)

внедрили модель DL для анализа КТ-ангиографии и достижения точного прогнозирования инсультов с окклюзией крупных сосудов, подчеркнув полезность DL в диагностике инсульта [78].

Тем не менее, применение DL в здравоохранении не ограничивается только визуализацией. Оно также продемонстрировало потенциал в области анализа данных электронной медицинской карты (EHR), прогнозирующего моделирования и мониторинга состояния здоровья. Миотто и соавт. (2018) использовали DL для прогнозирования начала заболевания при EHRs, что еще больше расширило область его применения [79].

Параллельно с ростом DL IoMT начала революционизировать здравоохранение, обещая улучшение результатов лечения пациентов, повышение рентабельности лечения и операционной эффективности [80]. IoMT обеспечивает взаимосвязь между медицинскими устройствами и ИТ-системами здравоохранения, позволяя осуществлять мониторинг пациентов и сбор данных в режиме реального времени, что в конечном итоге приводит к улучшению процесса принятия клинических решений [81].

Однако литературы, конкретно посвященной применению IoMT в лечении инсульта, по-прежнему мало. Несколько существующих исследований в основном посвящены роли IoMT в мониторинге жизненно важных параметров пациентов и реабилитации после инсульта [82]. Объединив непрерывный мониторинг жизненно важных показателей с системами экстренной медицинской помощи, Tang и соавт. (2017) продемонстрировали потенциал IoMT для улучшения догоспитальной помощи пациентам, перенесшим инсульт [83]. Аналогичным образом, Ян и соавт. (2018) разработали реабилитационную систему на основе IoMT, продемонстрировав ее полезность в восстановлении после инсульта и реабилитации [84].

Конвергенция DL и IoMT - это новая тема в здравоохранении, лежащая в основе смены парадигмы в сторону более интегрированного ухода за пациентами, основанного на данных [85]. Слияние этих двух технологий обещает достичь новых уровней эффективности, точности и расширения прав и возможностей пациентов при оказании медицинской помощи [86]. Тем не менее, применение этого комплексного подхода к лечению инсульта, в частности, анализ КТ-изображений головного мозга, остается в значительной степени неизученным, что указывает на пробел в литературе, который наше исследование стремится заполнить.

Объединение DL и IoMT открывает новые горизонты в диагностике и лечении инсульта. Хотя обе технологии по отдельности продемонстрировали свою эффективность в здравоохранении, их совместное применение для анализа КТ-изображений головного мозга пациентов, перенесших инсульт, является новым достижением. Наше исследование находится на стыке этих двух направлений и направлено на дальнейшее расширение возможностей, что позволяет быстрее и точнее диагностировать инсульт и способствует своевременному вмешательству.

Эта работа представляет собой обзор различных моделей и передовых методов визуализации в диагностике и лечении инсульта [87]-[99].

Авторы [100] предлагают обнаруживать инсульт в режиме реального времени, а также генерировать сигналы тревоги при пробуждении с помощью Интернета вещей. Эта система является самообучающейся, где используются алгоритмы и методы машинного и глубокого обучения, кроме того, она собирает данные из медицинской карты, физиологические данные, изменения во время движения тела с помощью носимых датчиков. При изучении сердца ученые также обнаружили, что появление круглосуточных носимых ЭКГ и имплантируемых электронных устройств в сердце, а именно кардиостимуляторов, выявило субклиническую ФП и ФП, определяемую устройством, что увеличило доступность определенных факторов риска развития инсульта [101]-[103]. Благодаря доступности данных ЭКГ и других кардиологических факторов риска, связанных с инсультом, их можно непрерывно отслеживать и анализировать с помощью носимых устройств в режиме реального времени [104]. Исследователи [105] предлагают мобильное приложение для распознавания мозгового инсульта в соответствии с тремя основными факторами, такими как неспособность улыбаться, нарушение координации из-за ограниченной подвижности и отсутствие связности речи. Система EmoStrokeSys, предложенная в [106], включает в себя три носимых датчика для измерения уровня глюкозы, измерения артериального давления и определения уровня стресса. Эта система отслеживает все параметры и последствия хронического стресса, которые могут привести к инсульту. Исследователи [107] представили ультразвуковой пластырь для непрерывной допплеровской визуализации без помощи рук, который крепится к шее и отслеживает показатели допплеровского кровотока в общей сонной артерии с помощью автоматизированного алгоритма. Это оборудование продемонстрировало, что изменения скорости были точно измерены с использованием как ручных, так и автоматически отслеживаемых допплеровских сигналов скорости. Устройство представляет собой носимый каротидный допплеровский пластырь, который также прост в использовании. Оно непрерывно записывает допплеровские спектrogramмы на протяжении многих сердечных и дыхательных циклов.

## **2. ПОДХОДЫ И СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ ДИАГНОСТИКИ ИНСУЛЬТА**

Визуальная диагностика стала важным инструментом для клинического использования. Изображения при обследовании предоставляют информацию об анатомии и физиологии внутренних органов тела или отдельных органов. Все это делается неинвазивным способом, безопасно и безболезненно. Однако эти изображения могут содержать информацию, невидимую для зрительной системы человека, но для получения этой информации можно использовать компьютерный анализ. Автоматизированная диагностическая система (САПР) является эффективным инструментом для получения хорошего уровня детализации для поддержки клинического диагноза. Предложение САПР состоит не в том, чтобы заменить врача, а в том, чтобы помочь специалисту интерпретировать результаты обследований, используя систему, которая предоставляет второе мнение или клиническое заключение и которая основана на автоматическом количественном анализе [108].

САПР-системы привлекли внимание ученых, исследователей и радиологов, поскольку они являются сложной темой исследований и обладают большим потенциалом в клиническом применении. Разработка этих систем имеет чрезвычайное значение для предоперационных и послеоперационных вмешательств, поскольку это сокращает количество ложноположительных результатов и время для постановки точного диагноза, а также уменьшает меж- и интраоперационную вариабельность специалистов. Технологические достижения последнего десятилетия и множество многообещающих исследовательских проектов продемонстрировали эффективность САПР-систем [109]. Его основная цель состояла в том, чтобы предоставить рентгенологам второе мнение при ознакомлении с их случаями [110]. В САПР произошли значительные изменения, и были внедрены приложения для всех типов медицинской визуализации. Хотя САПР-системы широко доступны, их внедрение в клиническую практику зависит от клинического сценария, в котором они используются. В первые годы после появления концепции САПР большинство разработанных алгоритмов были направлены на раннее выявление рака молочной железы на маммограммах и выявление рака легких на рентгенограммах грудной клетки или компьютерной томографии. В настоящее время САПР-системы хорошо зарекомендовали себя при оказании помощи в диагностике инсульта и во многих других областях медицины.

САПР-системы для инсульта предназначены для обнаружения, определения области и классификации типа инсульта. Brain Dock R использует эти системы для лечения цереброваскулярных заболеваний, и они широко используются для выявления бессимптомных заболеваний головного мозга [111]. Многие другие системы все еще находятся на первых стадиях разработки и используются только в научных исследованиях [112] [113]. Практические и бюрократические факторы, такие как клиническая валидация, нормативное и экономическое одобрение, являются ограничивающим фактором для интеграции этих систем в клиническую практику [114].

## 2.1 Обзор методов машинного обучения и глубокого обучения

Методы машинного обучения подразделяются на три категории: обучение с учителем, без учителя и обучение с подкреплением (RL). Обучение с поддержкой использует алгоритмы из всех ветвей в различных сценариях, как показано на рисунке 2.1. Здесь мы кратко рассмотрим контролируемое и неконтролируемое обучение с примерами. Затем мы представим обучение с поддержкой и его основные алгоритмы.

В обучении с учителем используется набор входных и целевых значений для обучения искусственной нейронной сети (ИНС) находить функцию отображения ввода на вывод. Контролируемое обучение дополнительно подразделяется на регрессию и классификацию. Некоторые хорошо известные примеры контролируемого обучения - это линейная регрессия, метод опорных векторов и случайный лес.

В обучении без учителя нет конкретных инструкций, а предоставляется только неклассифицированный и неспецифицированный набор входных данных, который используется для обучения искусственной нейронной сети находить скрытые паттерны, ответы и распределения. Различные типы задач неконтролируемого обучения - это кластеризация и ассоциация. Некоторые примеры - это алгоритм k-средних и автоэнкодер.

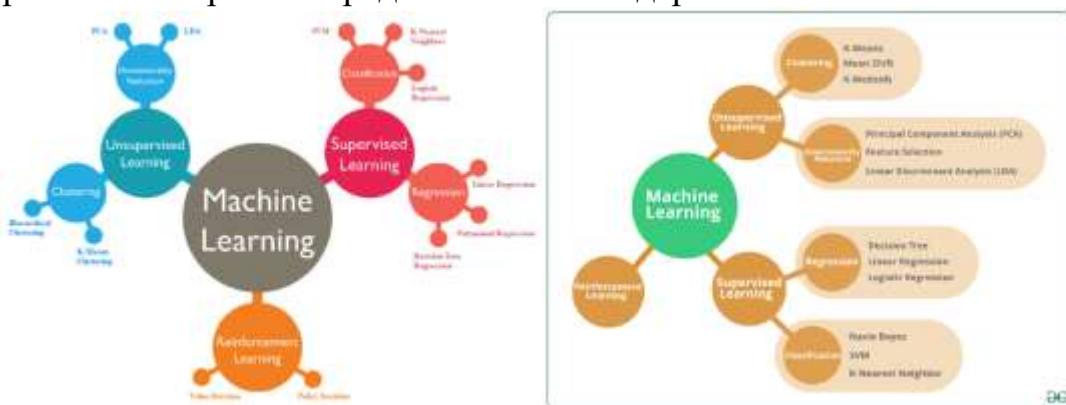


Рисунок 2.1 Классификация методов машинного обучения

### 2.1.1 Обучение с учителем

#### Логистическая регрессия

Логистическая регрессия (ЛР) - это метод обучения с учителем, применяемый при непрерывных/дискретных предикторах и дихотомической (например, диабет против контроля) зависимой переменной. ЛР оценивает вероятность бинарного ответа на основе одного или нескольких предикторов. Модель измеряет отношения между ответом и предикторами, оценивая логит-функцию вероятности. Логарифм переменной ответа ( $Y$ ) представляет собой линейную комбинацию предикторов ( $X$ ), представленную следующим образом:

$$\text{logit}(P_j) = \log_e \left( \frac{P_j}{1 - P_j} \right) = \sum_{i=0}^K \beta_i X_i \quad (1)$$

здесь  $P_j$  - это вероятность для  $Y=1$  (диабет),  $1 - P_j$  - вероятность для  $Y=0$  (контроль),  $\beta_i$ 's ( $i = 0, 1, \dots, K$ ) - неизвестные коэффициенты регрессии,  $K$  - общее количество предикторов (14 факторов),  $X_i$ 's ( $i = 1, \dots, K$ ) - предикторы, и  $X_0 = 1$ . Коэффициенты регрессии оцениваются с использованием метода максимального правдоподобия (ММП), и отношения шансов ИЛИ получаются экспонентой коэффициентов регрессии. Значимость можно проверить, используя z-тест, выбирая признаки, соответствующие коэффициентам/ИЛИ с p-значениями менее 0,05.

### *Наивный байес*

Наивный байес (NB) - это вероятностный классификатор, основанный на теореме Байеса с предположением о взаимной независимости признаков [48]. Используется для диагностики различных заболеваний, включая сердечно-сосудистые, диабетические и онкологические проблемы классификации [115-118] Классификатор NB основан на теореме Байеса:

$$P(z|w_1, \dots, w_n) = \frac{P(z)\pi_{i=1}^n P(w_i|z)}{\pi_{i=1}^n P(w_i)} \quad (2)$$

здесь  $z$  - это зависимая переменная,  $w_1, w_2, \dots, w_n$  - входные переменные,  $P(z|w_1, \dots, w_n)$  - условное распределение вероятности  $z$  при условии  $w_1, w_2, \dots, w_n$ ;  $P(z)$  - маргинальное распределение вероятности  $z$ ,  $P(w_i|z)$  - условное распределение вероятности  $w_i$  при условии  $z$ , и  $p(w_i)$  - маргинальное распределение вероятности  $w_i$ ;  $\pi$  символ произведения. Классификатор присваивает метку класса на основе вывода с максимальной вероятностью.

$$z = \operatorname{argmax}_z P(z)\pi_{i=1}^n P(w_i|z) \quad (3)$$

### *Дерево решений (DT)*

Дерево решений (DT) - это модель обучения с учителем, используемая как дерево регрессии для непрерывных зависимых переменных и как дерево классификации, когда зависимая переменная может быть разделена на группы. Дерево решений строит структуру дерева на основе входных признаков, выбирая объекты, предоставляемые наибольший поток информации для прогнозирования вывода [119] [120]. Шаги включают построение дерева, выбор объектов для прогнозирования вывода и формирование поддеревьев на основе неиспользованных объектов [121].

### *Случайный лес (RF)*

Случайный лес (RF) - это классификатор на основе машинного обучения, строящий деревья решений. Этот алгоритм был впервые предложен Брайманом [122]. Может использоваться как для регрессии, так и для классификации. RF применяется в биомедицинских исследованиях, для ранней диагностики болезней сердца, рака, инсульта, диабета и др. [115] [123-127]. Шаги включают разделение набора данных на обучающий и тестовый наборы, построение деревьев решений на основе бутстрэп-выборок и использование каждого дерева для голосования за входные переменные. Классификация определяется средним числом голосов.

### *Adaboost*

Adaboost (AB) - это метод обучения с учителем, использующий адаптивное усиление для повышения производительности классификатора. Френд и Шапиро представили алгоритм адаптивного улучшения в 1996 году и получили премию Геделя в 2003 году за свои достижения [128] [129]. Он используется в сочетании с различными типами алгоритмов для повышения производительности классификатора. Адаптивное усиление чувствительно к зашумленным данным и выбросам, но менее подвержено проблеме переобучения, чем другие алгоритмы обучения. Каждый алгоритм обучения имеет тенденцию лучше подходить к некоторым типам задач и обычно имеет множество различных характеристик и типов, которые нужно настроить перед достижением оптимальной производительности для набора данных. Адаптивное усиление считается лучшим классификатором «из коробки» [130].

### *Метод опорных векторов (SVM)*

Метод опорных векторов (SVM) изначально использовался для решения проблемы бинарной классификации. Основная идея - получить гиперплоскость с максимальным расстоянием между двумя видами данных. Предположим, что существует линейно разделяемый набор данных  $\{x_i, y_i\} (i = 1, 2, \dots, N), x_i \in R^d$  - входная переменная, а  $y_i \in \{+1, -1\}$  - соответствующая переменная классификации. При линейно разделяемых условиях предположим, что данные удовлетворяют:

$$y_i(w \cdot x_i + b) \geq +1 \quad (4)$$

w - вектор строки с той же размерностью, что и входная переменная  $x_i$ , b - скаляр

При условии линейной неразделимости вводится релаксационная переменная  $0(1, 2, , ) \varepsilon_i \geq =0 (i = 1, 2, \dots, N)$  для указания степени отклонения ошибок классификации.

$$y_i(w \cdot x_i + b) + \varepsilon_i \geq +1 \quad (5)$$

На этом этапе должна быть удовлетворена оптимальная гиперплоскость:

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \varepsilon_i \quad (6)$$

C - это параметры штрафа модели.

Чтобы решить нелинейную разделимую задачу, нелинейная задача может быть преобразована в линейную задачу в пространстве большей размерности, поэтому входные переменные должны быть сопоставлены с пространством большей размерности с помощью функции ядра  $K(x_i, x_j)$ .

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)_i \quad (7)$$

[65]-[69]

SVM может быть адаптирован для проблемы нелинейной разделимости, преобразовав ее в линейную проблему в пространстве более высокой размерности с использованием ядерной функции. Радиальная базисная функция - часто используемая ядерная функция.

### *K- Ближайшие соседи (kNN)*

Подход k-ближайших соседей (kNN) [131] классифицирует тестовые образцы, передавая большинственную метку k ближайших обучающих соседей соответствующему тестовому случаю. Хотя в прошлом было предложено несколько определений расстояний, наиболее часто используется евклидово расстояние, которое также используется в этом исследовании. Классификаторы kNN не делают обобщений на основе обучающего набора, а просто хранят обучающие данные. Было обнаружено, что модели k-ближайших соседей, сопоставимые с классификаторами GNB, хорошо работают для многих задач классификации в реальном мире. Выбор k является решающим фактором: более высокие значения k уменьшают эффекты шума, в то время как более низкие значения приводят к более четким границам классов. Как дополнительный параметр, голоса обучающих образцов могут взвешиваться их расстоянием. Однако эта функция не используется в исследовании [132]-[135] для обеспечения максимальной простоты метода.

### 2.1.2 Обучение без учителя

Обучение без учителя может быть полезно для поиска новых путей развития заболевания, генотипов и фенотипов. Примеры неконтролируемого обучения включают K-средние, смещение среднего, распространение аффинности, иерархическую кластеризацию и моделирование гауссовой смеси.

#### *K-средние*

Кластеризация K-средних - это метод поиска кластеров и центров кластеров в наборе немаркированных данных [132] [133]. Учитывая исходный набор центров, алгоритм K-средних чередует два шага:

- Для каждого центра определено подмножество тренировочных точек, которое находится ближе к нему, чем к любому другому центру.
- Вычисляются средние значения каждого объекта для точек данных в каждом кластере, и этот средний вектор становится новым центром для этого кластера.

K-среднее значение создает низкочастотные паттерны, поскольку энергия изображения сосредоточена в низкочастотном диапазоне [134]. Отбеливание используется для получения высокочастотных компонентов в изображении, а предварительно обработанные отбеленные данные представлены символом "xp", восстановительный словарь  $D \in \mathbb{R}^{pxK}$  с K элементами строится путем оптимизации уравнения (8).

$$\langle D, s \rangle = \underset{D, s}{\operatorname{argmin}} \sum_{i=1}^n \|x_p - Ds\|_2^2 \quad \text{subject to } \|s\|_0 \leq 1, \quad (8)$$

где  $\|x_p - Ds\|_2^2$  обозначает ошибку восстановления,  $s_i \in \mathbb{R}^K$  обозначает вектор признаков, соответствующий новому предварительно обработанному патчу  $x_{p,i}$ , и  $D = [d_1, d_2, \dots, d_K] \in \mathbb{R}^{p \times K}$  ( $K > p$ , делает словарь более полным). Каждый столбец в словаре представляет центроиды, полученные с помощью K-средних. Пример визуализации изученного словаря (банка фильтров) показан на рис. 6.

Алгоритм К-средних приближенно оптимизирует невыпуклое целевое уравнение (8), альтернативно выполняя точную минимизацию по отношению к меткам "s" с фиксированным значением "D" и по отношению к "D" с фиксированными метками.

Чтобы связать кластеризацию с матричной факторизацией, уравнение (8) переформулируется следующим образом:

$$\langle D, s \rangle = \underset{D, s}{\operatorname{argmin}} \frac{1}{n} \sum_{i=1}^n \frac{1}{2} \|x_p - Ds\|_2^2 \quad \text{subject to } \|s\|_0 \leq 1, \quad (9)$$

Кластеризация К-средних выполняется очень быстро, не требует настройки гиперпараметров и масштабируема, поэтому мы включили подход неконтролируемого изучения признаков в задачу выявления субактивного очага ишемического инсульта. Kmeans изучает разреженное представление входных данных, когда имеется большое количество обучающих изображений, соответствующих размеру входного изображения. K-means выбран потому, что имеется большой объем немаркированных данных и аннотации становятся дорогостоящими [135]-[137].

### *K-медиоиды*

Вместо того, чтобы использовать среднее значение объектов в кластере за пределами контрольной точки, вы можете использовать фактический объект. Цель состоит в том, чтобы найти объект, наиболее расположенный в центре кластера, который называется *honeyoid*, и объекты, которые находятся ближе всего, присваиваются *honeyoid* для создания кластеров [138] [139]. Согласно Han et al. (2012) [140], критерий абсолютной погрешности определяется как

$$E = \sum_{i=1}^k \sum_{p \in C_i} \operatorname{dist}(p, o_i) \quad (10)$$

где  $E$  - сумма абсолютной ошибки для всех объектов  $p$  в наборе данных, а  $o_i$  - репрезентативный объект  $C_i$ . Это основа метода k-medoids, который группирует  $n$  объектов в  $k$  кластеров путем минимизации абсолютной ошибки [141]-[144].

### *Методы иерархической кластеризации*

В методах иерархической кластеризации кластеры формируются путем итеративного разделения шаблонов с использованием подхода "сверху вниз" или "снизу вверх". Существует две формы иерархического метода, а именно агломеративная и разделяющая иерархическая кластеризация [145]. Агломеративный подход основан на подходе "снизу вверх", который создает кластеры, начиная с одного объекта, а затем объединяет эти атомарные кластеры во все более крупные кластеры, пока все объекты, наконец, не окажутся в одном кластере или иным образом, пока не будут выполнены определенные условия завершения. Отдельная иерархическая кластеризация основана на исходящем подходе, который разбивает кластер, содержащий все объекты, на более мелкие кластеры до тех пор, пока каждый объект не сформирует кластер самостоятельно или пока он не будет удовлетворять

определенным условиям завершения. Иерархические методы обычно приводят к формированию дендрограмм, как показано на рисунке 2.2 ниже.

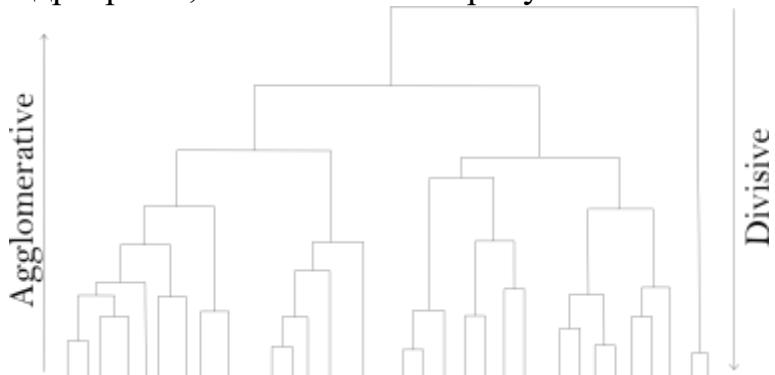


Рисунок 2.2 Дендрограмма иерархической кластеризации [78]

Методы иерархической кластеризации могут быть дополнительно сгруппированы в три категории на основе показателей сходства или взаимосвязей [146], как кратко описано в следующих разделах.

#### *Кластеризация с одной связью*

Этот тип кластеризации часто называют методом связности, минимальным методом или методом ближайшего соседа. При одноканальной кластеризации соединение между двумя кластерами осуществляется с использованием одной пары элементов, а именно тех двух элементов (по одному в каждом кластере), которые находятся ближе всего друг к другу. При такой кластеризации расстояние между двумя кластерами определяется ближайшим расстоянием от любого члена одного кластера до любого члена другого кластера, что также определяет сходство. Если данные представлены со сходством, то сходство между парой кластеров считается равным наибольшему сходству любого члена одного кластера с любым членом другого кластера [147]. На рисунке 2.3 показано отображение кластеризации с одним звеном.

Критерии между двумя наборами кластеров А и В следующие:

$$\min\{d(a, b) : a \in A, b \in B\} \quad (11)$$

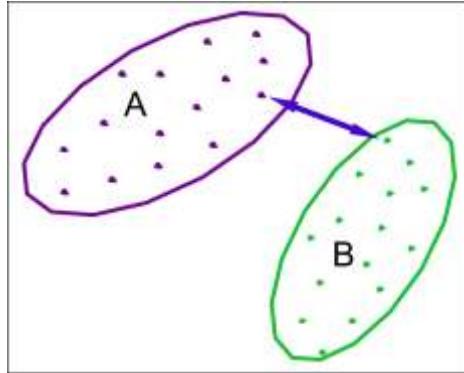


Рисунок 2.3 Отображение кластеризации с одной связью [139]

#### *Кластеризация с полной связью*

В кластеризации с полной связью также используется метод диаметра, максимального значения или метод самого дальнего соседа; расстояние между двумя кластерами определяется наибольшим расстоянием от любого элемента одного кластера до любого элемента другого кластера [148]. На рис. 2.4

показано отображение полной кластеризации связей. Критерии между двумя наборами кластеров А и В следующие:

$$\max\{d(a, b) : a \in A, b \in B\} \quad (12)$$

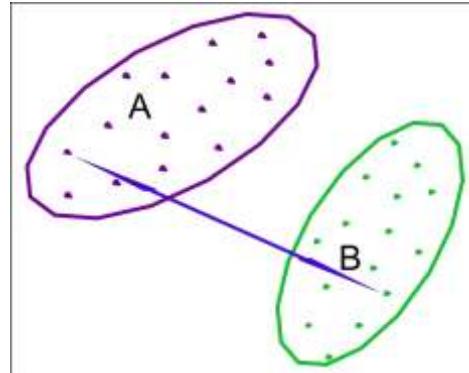


Рисунок 2.4 Отображение полной кластеризации связей [139]

В среднем кластеризация связей также известна как метод минимальной дисперсии; расстояние между двумя кластерами определяется средним расстоянием от любого члена одного кластера до любого члена другого кластера [149]. На рис. 2.5 показана карта средней кластеризации связей. Ниже показана достоверность между двумя наборами кластеров А и В:

$$\frac{1}{|A||B|} \sum_{a \in A} \sum_{b \in B} d(a, b) \quad (13)$$

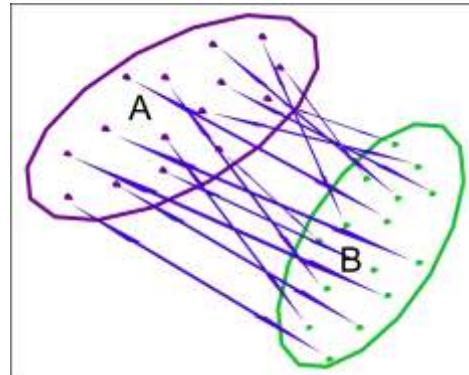


Рисунок 2.5. Отображение средней кластеризации связей [139]

Общим недостатком классических алгоритмов НС является то, что они ненадежны и, следовательно, чувствительны к шуму и излучениям. Как только объект назначен кластеру, он больше не будет учитываться, что означает, что алгоритмы НС не способны исправить возможную предыдущую ошибочную классификацию. Вычислительная сложность большинства алгоритмов НС составляет по меньшей мере  $O(N^2)$ , и эта высокая стоимость ограничивает их использование в крупномасштабных наборах данных. Другие недостатки НС включают тенденцию к образованию сферических фигур и феномен разворота, при котором нормальная иерархическая структура искажается [150].

### *Нечеткие С-средства*

Традиционные подходы к кластеризации создают разделы, в которых внутри раздела объект принадлежит одному и только одному кластеру. Таким

образом, это “жесткие” кластеры. Предполагалось, что нечеткая кластеризация решит эту проблему, предоставив объект, который будет подключен к кластеру с помощью функции принадлежности. Нечеткие с-средние (FCM) - это метод кластеризации, который позволяет одной точке принадлежать двум или более кластерам, в отличие от К-средних, где каждой точке присваивается только один кластер. Этот метод был разработан Даном в 1973 году [151] и усовершенствован Бездеком в 1981 году [152] [153]. Процедура для нечетких с-средних [150] аналогична процедуре нечетких К-средних. Она основана на минимизации следующей целевой функции:

$$J_m = \sum_{i=1}^N \sum_{j=1}^c u_{ij}^m \|x_i - v_j\|^2; 1 < m < \infty \quad (14)$$

где  $m$  - показатель матрицы нечеткого разбиения для управления степенью нечеткого перекрытия, при  $m > 1$ . Нечеткое перекрытие относится к тому, насколько нечеткими являются границы между кластерами, то есть количество точек данных, которые имеют значительное членство более чем в одном кластере,  $u_{ij}$  - степень членства  $x_i$  в кластере  $j$ ,  $x_i$  - это  $i$ -й шаблон данных  $d$ -измерения,  $v_j$  - центр  $j$ -го кластера  $d$ -измерения, а  $\|\cdot\|$  - любая норма, выражающая сходство между любыми измеренными данными и центром [154]-[156].

### *Модели смесей*

В некоторых случаях будет невозможно просто описать набор данных, используя одно распределение. Это особенно распространено, когда набор данных берется из двух или более субпопуляций. Следовательно, необходимо привести состав распределений в соответствие с базовым набором данных, где такие распределения называются смешанными моделями. Модели смесей определяются параметрами, специфичными для каждого компонента, и пропорцией, в которой происходит смешивание компонентов. Кластеризация объектов данных достигается путем определения параметров компонентов и, таким образом, классификации каждого объекта данных по соответствующему компоненту. Для характеристики этих моделей используются такие переменные, как дисперсия и среднее значение. Для подгонки распределений модели смеси можно использовать несколько методов, например, метод моментов, байесовские подходы, графические методы и оценка максимального правдоподобия (MLE). Наиболее широко используемым подходом является алгоритм максимизации математического ожидания (EM) для распределения MLE модели смеси [154].

### *Скрытые Марковские модели*

Скрытые Марковские модели относятся к группе кластеризации на основе моделей и полезны для данных заданных временных рядов. Используя скрытую марковскую модель, каждая точка данных представляет наблюдаемое значение временного ряда в момент времени  $t$ . Модель состоит из двух частей: (1) наблюдения временного ряда и (2) ненаблюдаемые переменные состояния, с помощью которых генерируются наблюдения временного ряда.

Модель характеризуется набором состояний, начальным распределением вероятностей для первого состояния, матрицей вероятностей перехода, соединяющей последовательные состояния, и зависящими от состояния распределениями вероятностей, ответственными за генерацию данных временных рядов. Наблюдатель может видеть только наблюдения временных рядов, в то время как переменные состояния скрыты. Скрытая марковская модель предоставляет статистические данные, такие как среднее значение, стандартное отклонение и весовые значения для кластера, в соответствии с наблюдениями, содержащими кластер [155] [156].

#### *Анализ основных компонентов (PCA)*

По сути, базовые компоненты (BCs) упорядочены таким образом, что первый BC объясняет основную часть дисперсии в данных, а на каждый последующий компонент приходится наибольшая доля вариабельности, которая не была учтена его предшественниками [200-203]. Чтобы лучше прояснить влияние каждой исходной переменной в BC, обычно определяется алгоритм вращения, такой как вращение varimax, для получения нагрузок коэффициента вращения, представляющих вклад каждой переменной в конкретный BC. Вращение Varimax может обеспечить максимальную корреляцию каждой переменной только с одним основным компонентом и почти нулевую связь с другими компонентами [204]. Метод, используемый в этой статье, заключается в оптимизации пространственных моделей и устранении мультиколлинеарности, которая, вероятно, подразумевалась между станциями.

Основными результатами АТР являются факторные нагрузки, которые отражают, насколько переменная влияет на данный конкретный BC и насколько хорошо одна переменная похожа на другие. Чем больше нагрузка переменной, тем больше эта переменная вносит вклад в изменение, учитываемое конкретным BC. На практике для объяснения основного компонента выбираются только нагрузки с абсолютными значениями, превышающими 0,5 [205]. BC с собственным значением, большим или равным 1, обычно рассматривается как имеющий статистическую значимость [206]. В этом исследовании наборы данных были проанализированы PCA с использованием коммерческого программного обеспечения SPSS 14.

### **2.1.3 Обучение с подкреплением**

Обучение с подкреплением похоже на многие темы, названия которых заканчиваются на -английский, такие как машинное обучение, планирование и альпинизм, в том смысле, что это одновременно проблема, класс методов решения, которые хорошо работают над группой проблем, и область, изучающая эти проблемы и методы их решения. Проблемы обучения с подкреплением включают в себя изучение того, что необходимо сделать — как соотнести ситуации с действиями — чтобы максимизировать числовой сигнал вознаграждения. В глобальном смысле это закрытые проблемы, потому что действия обучающей системы влияют на ее последующий ввод. Более того, в

процессе обучения студенту не говорят, какие действия следует предпринять, как во многих формах машинного обучения, но вместо этого он должен выяснить, какие решения приносят наибольшую выгоду, протестирував их. В наиболее интересных и сложных случаях действия могут повлиять не только на непосредственное вознаграждение, но и на следующую ситуацию, а через нее и на все последующие этапы далее по цепочке. Эти три характеристики — будучи по существу закрытыми, без прямых инструкций о том, какие действия следует предпринять и где последствия действий, включая сигналы вознаграждения, проявляются в течение длительных периодов времени — являются тремя наиболее важными отличительными чертами проблем обучения с подкреплением.

Полное описание целей обучения с подкреплением в терминах оптимального управления марковскими процессами принятия решений следует отложить до главы 3, но основная идея заключается просто в изучении всех важных аспектов реальной проблемы, с которой сталкивается обучающийся агент, взаимодействующий со своим окружением для достижения цели. Очевидно, что такой агент должен быть способен в какой-то степени чувствовать состояние окружающей среды и должен быть способен предпринимать действия, влияющие на это состояние. У агента также должны быть задачи и цели, связанные с состоянием окружающей среды. Эта формулировка предназначена для того, чтобы включить только эти три аспекта — действие, ощущение и цель — в их простейших возможных формах, не упрощая ни один из них.

Любой метод, который может хорошо решать такие проблемы, мы рассматриваем как метод обучения с подкреплением. Усиленное обучение отличается от контролируемого обучения, которое изучается в большинстве современных исследований машинного обучения. Контролируемое обучение — это обучение, основанное на обучающем наборе помеченных примеров, предоставленных знающим внешним руководителем. Каждый пример представляет собой описание ситуации вместе со спецификацией-меткой — правильным действием, которое система должна предпринять в данной ситуации, которое часто заключается в определении категории, к которой относится данная ситуация. Цель такого рода обучения состоит в том, чтобы система экстраполировала или обобщила свои реакции таким образом, чтобы она действовала правильно в ситуациях, которых нет в обучающем наборе. Это важный тип обучения, но сам по себе его недостаточно для обучения, основанного на взаимодействии. В интерактивных задачах часто нецелесообразно получать примеры желаемого поведения, которые являются одновременно правильными и репрезентативными для всех ситуаций, в которых агент должен действовать. На неизведанной территории — где, как вы могли бы ожидать, обучение будет наиболее полезным — агент должен уметь учиться на собственном опыте.

Усиленное обучение также отличается от того, что исследователи машинного обучения называют неконтролируемым обучением, которое обычно

включает в себя поиск структуры, скрытой в немаркированных наборах данных. Термины “контролируемое обучение” и “неконтролируемое обучение”, кажется, всесторонне классифицируют парадигмы машинного обучения, но это не так. Хотя может возникнуть соблазн рассматривать усиленное обучение как разновидность неконтролируемого обучения, поскольку оно не опирается на примеры правильного поведения, усиленное обучение пытается максимизировать сигнал вознаграждения вместо того, чтобы пытаться найти скрытую структуру. Раскрытие структуры в опыте агента, безусловно, может быть полезно при обучении с подкреплением, но само по себе не решает проблему агента, обучающегося с подкреплением, связанную с максимизацией сигнала вознаграждения. Таким образом, мы рассматриваем усиленное обучение как третью парадигму машинного обучения, наряду с контролируемым обучением, неконтролируемым обучением и, возможно, другими парадигмами.

Одной из проблем, возникающих при обучении с подкреплением, а не при других видах обучения, является компромисс между исследованием и эксплуатацией. Чтобы получить крупное вознаграждение, агент по обучению с подкреплением должен предпочесть действия, которые он пробовал в прошлом и которые оказались эффективными для получения вознаграждения. Но чтобы обнаружить такие действия, он должен попробовать действия, которые он не выбирал раньше. Агент должен использовать то, что он уже знает, чтобы получить вознаграждение, но он также должен провести исследование, чтобы сделать наилучший выбор действий в будущем. Дilemma заключается в том, что ни разведка, ни эксплуатация не могут осуществляться исключительно без невыполнения этой задачи. Агент должен пробовать различные действия и постепенно отдавать предпочтение тем, которые кажутся ему лучшими. В стохастической задаче каждое действие должно быть многократно проверено, чтобы получить надежную оценку ожидаемого вознаграждения. Дilemma исследования и эксплуатации активно изучалась математиками на протяжении многих десятилетий. Тем временем мы просто замечаем, что весь вопрос о балансе разведки и эксплуатации даже не возникает при контролируемом и неконтролируемом обучении, по крайней мере в их строгих формах.

Другой ключевой особенностью обучения с подкреплением является то, что оно явно решает всю проблему взаимодействия целевого агента с неопределенной средой. Это отличается от многих подходов, которые рассматривают подзадачи без учета того, как они могут вписаться в общую картину. Например, мы уже упоминали, что большинство исследований в области машинного обучения связано с обучением под наблюдением, без явного указания того, насколько такая способность в конечном итоге будет полезна. Другие исследователи разработали теории планирования с общими целями, но без учета роли планирования в принятии решений в режиме реального времени или вопроса о том, откуда берутся прогностические модели, необходимые для планирования. Хотя эти подходы дали много полезных

результатов, их сосредоточенность на изолированных подзадачах является существенным ограничением.

Обучение с подкреплением следует противоположному пути, начиная с полноценного, интерактивного, целеустремленного агента. Все агенты, обучающиеся с подкреплением, имеют четкие цели, могут ощущать аспекты своего окружения и могут выбирать действия, влияющие на их окружение. Более того, обычно с самого начала предполагается, что агент должен действовать, несмотря на значительную неопределенность относительно окружающей среды, с которой он сталкивается. Когда усиленное обучение предполагает планирование, оно должно учитывать взаимодействие между планированием и выбором действий в режиме реального времени, а также то, как приобретаются и совершенствуются модели окружающей среды. Когда усиленное обучение предполагает обучение под наблюдением, это происходит по определенным причинам, которые определяют, какие способности являются критическими, а какие нет. Чтобы обучать исследованиям для достижения прогресса, важные подзадачи должны быть выделены и изучены, но это должны быть подзадачи, которые играют очевидную роль в наборе интерактивных, целенаправленных агентов, даже если все детали в наборе агентов еще не могут быть заполнены.

Почти все базовые алгоритмы обучения с подкреплением описаны ниже в их простейших формах, в которых пространства состояний и действий достаточно малы, чтобы приблизительная функция значения действия была представлена в виде массива или таблицы. В этом случае методы часто могут находить точные решения, то есть они часто могут найти оптимальную функцию значений и оптимальную политику.

Марковский процесс принятия решений (MDP) Большинство задач RL основаны на Марковском процессе принятия решений (MDP). Целью MDP является поиск оптимальных решений задач с последовательным решением (SDP). В случае стохастических SDP, MDP не может предоставить абсолютных решений, но может помочь предложить наилучшее из всех возможных решений. Модель MDP определяется набором состояний, набором действий, моделью перехода и функцией вознаграждения. Вознаграждение и переход зависят от текущего состояния, выбранного действия и следующего результирующего состояния [207].

Целью агента RL является повышение своего долгосрочного совокупного вознаграждения на основе его многочисленных взаимодействий с данной средой. Часть алгоритма RL, которая выполняет взаимодействие и учится, известна как агент. Агент достиг этой цели с помощью оптимальных политик. Политика - это последовательность действий при заданном наборе условий, а оптимальная политика - это та, которая максимизирует общее долгосрочное вознаграждение. Наиболее важной задачей для агента является использование уже известных действий и в то же время изучение новых действий, которые могут обеспечить лучшее вознаграждение по сравнению с существующими лучшими действиями. Баланс между разведкой и эксплуатацией является

центральным вопросом при установке RL, то есть баланс между максимизацией прибыли от известных ходов или поиском новых горизонтов, которые могут даже дать лучший результат. Как правило, алгоритмы RL можно разделить на два типа: основанные на модели и безмодельные. Алгоритмы RL, основанные на моделях, используют аппроксиматор функций и рассматриваются как примеры эффективных. Однако обобщение является важной проблемой в RL, а алгоритмы обобщения на основе моделей для вероятностных, сложных и крупномерных моделей не подходят. Различные методы решения задач RL на основе моделей включают поиск политики, функцию возврата, функцию значения и модели переходов. Монте-Карло (MC) и разница во времени (TD) являются безмодельными алгоритмами RL. Методы Q-Learning и SARSA, которые будут объяснены позже, являются примерами метода TD [208].

Динамическое программирование (DP), разработанное Ричардом Беллманом в середине двадцатого века, представляет собой компьютерное программирование и математический метод, используемый для решения задач оптимизации. DP - это рекурсивный метод, который последовательно разбивает сложную задачу на более простые и мелкие задачи. Подход DP основан на модели, которая требует полного наблюдаемого знания окружающей среды. Следовательно, в некоторых задачах RL, где эта модель среды является моделью MDP, DP используется для нахождения оптимальной политики с использованием итерации значений или метода итерации политики [209].

*Метод Монте-Карло (MC)* использует случайность для решения задач. Первое посещение MC и каждое посещение MC - это два разных метода MC [113]. Первое посещение MC - это среднее количество возвращений после первых посещений штата в течение набора эпизодов, в то время как среднее количество возвращений после всех посещений штата в течение набора эпизодов - это каждое посещение MC. Основные преимущества MC по сравнению с DP заключаются в том, что:

- 1) Его можно использовать с модельными моделями.
- 2) Алгоритмы MC эффективны и просты в реализации.
- 3) MC изучает оптимальные решения посредством прямого взаимодействия.

Методы временной разницы Проблема в методах MC заключается в том, что вам нужно дождаться окончания эпизода для обновления, и эта проблема будет решена методами временной разницы (TD), класс метода modelfree RL algorithm td изучается путем начальной загрузки из вычисления функции текущего значения [210] . В общем, TD используется для прогнозирования значения, которое зависит от будущих значений данного сигнала, но в рамках RL оно используется для прогнозирования долгосрочных будущих вознаграждений. Это один из наиболее широко используемых методов оценки политики. Двумя основными алгоритмами, основанными на TD, являются Q-learning и SARSA, которые кратко описаны ниже.

SARSA State-Action-Reward-State-Action (SARSA), предложенный Саттоном [211] как “модифицированное Q-обучение” из-за его сходства с Q-

learning, и позже Саттон назвал его SARSA-активным методом управления RL-TD. Это похоже на Q-learning, за исключением того, что SARSA является алгоритмом обучения, основанным на политике. Как следует из названия, это обновление основано на State-ActionReward-state-action'. Таким образом, он узнает оптимальное значение Q из результатов действий, выполняемых, следуя этой политике, а не жадничая.

### *Q-метод обучения*

Q-learning предлагается использовать в качестве подхода DRL в непредсказуемой среде. Q-learning - это безмодельный, неполитический и перспективный алгоритм обучения TD [211] для управления. Алгоритм Q-learning изучает оптимальную политику, используя off policy, то есть обучение наблюдению. При Q-обучении следующее действие a 'выбирается для максимального Q-значения следующего состояния, которое является жадной политикой и не следует этой политике, то есть это неполитическое обучение. Мы также можем ускорить конвергенцию в Q-learning и SARSA, используя трассировки соответствия требованиям. Эффективность предыдущего протокола становится низкой в случае дискретных действий и большого количества повторяющихся состояний. Чаще всего метод Q-learning требует аппроксимации функций.

### *Алгоритм актера–критика*

Методика актера-критики основана на популярных алгоритмах RL. Это гибридный метод, состоящий из функции политики и ценности. Критическая часть алгоритма оценивает функцию ценности, в то время как актер обновляет политику в соответствии с отзывами критика. Этот тип метода находится между методами, основанными на политике, и методами, основанными на ценностях; то есть он оценивает как политику, так и функцию ценности. Это применимо как к небольшим областям государственной деятельности, так и к большим областям государственной деятельности. Цель предыдущей методики состоит в том, чтобы соединить методы только для актера и только для критика. Для изучения функции ценности метод критика использует моделирование и структуру аппроксимации. Функция ценности затем используется для обновления политических ценностей субъекта для повышения эффективности [212].

Байесовские методы в DRL-агенте получают разные вознаграждения от разных состояний и, несомненно, со временем будут увеличивать вознаграждение. Агент приучает себя переключаться на состояния с наибольшим вознаграждением, избегая состояний, основанных на наименьшем вознаграждении. Это информация о неопределенности окружающей среды, которая играет жизненно важную роль в максимизации вознаграждений. Байесовские модели предоставляют аналитическую архитектуру для оценки и изучения неопределенностей модели при достаточных вычислительных затратах [213]. Байесовские методы могут быть решением дилеммы "эксплуатация-разведка" из-за их способности учитывать неопределенности в изучаемых параметрах и избегать переобучения. Несколько хорошо известных

методов, используемых для байесовской аппроксимации, - это выборки Миопика и Томпсона. Выборка Томпсона может быть использована для решения задачи разведки и разработки месторождений. Алгоритм TD Deep Q Network, особенно Q-learning, является одним из широко используемых алгоритмов в RL, но у него нет проблем общности в большом пространстве состояний. В предыдущих методах мы сохраняли значение функции в справочной таблице или матрице. Например, в Q-learning мы сохраняем таблицу Q в двумерном массиве. В средах с большим пространством состояний и множеством связанных действий сложно просмотреть и оценить функцию значений для всех состояний. С внедрением RL на основе нейронных сетей для аппроксимации функций проблема обобщения может быть преодолена. Сеть глубокого Q (DQN) [211] использует нейронную сеть для оценки функции значений в большом пространстве состояний. Обучение сети осуществляется с использованием правила обновления Q-learning. [214]-[216]

#### **2.1.4 Искусственная нейронная сеть**

Искусственные нейронные сети (ANNs) - одна из самых известных моделей машинного обучения, представленная еще в 1950-х годах и активно изучаемая с тех пор [216].

Грубо говоря, нейронная сеть состоит из нескольких подключенных вычислительных блоков, называемых нейронами, расположенных слоями. Существует входной уровень, на котором данные поступают в сеть, а затем один или несколько скрытых слоев преобразуют данные по мере их прохождения, прежде чем попасть на выходной уровень, который делает предсказания нейронной сети. Сеть учится получать полезные прогнозы, идентифицируя закономерности в наборе помеченных обучающих данных, передаваемых через сеть, в то время как выходные данные сравниваются с фактическими метками целевой функции. Во время обучения параметры сети — сила каждого нейрона — настраиваются до тех пор, пока паттерны, идентифицированные сетью, не приведут к хорошим прогнозам для обучающих данных. После того, как паттерны изучены, сеть можно использовать для прогнозирования новых, невидимых данных, т.е. для обобщения на новые данные.

Давно известно, что ANN очень гибкие, способные создавать и решать сложные задачи, но также и тот факт, что их сложно и очень дорого обучать с точки зрения вычислений. Это снижало их практическую полезность и заставляло людей до недавнего времени сосредотачиваться на других моделях машинного обучения. Но на сегодняшний день искусственные нейронные сети являются одним из используемых методов машинного обучения, причем наиболее интенсивно изучаемым. Это изменение связано с ростом объема больших данных, мощными процессорами для параллельных вычислений (в частности, графическими процессорами), некоторыми важными изменениями в алгоритмах, используемых для построения и обучения сетей, а также разработкой простых в использовании программных платформ. Всплеск

интереса к ANNS приводит к невероятным темпам развития, которые наряду с этим стимулируют другие части машинного обучения.

Книги, находящиеся в свободном доступе [216] [217], являются двумя из многих отличных источников, позволяющих узнать больше об искусственных нейронных сетях. Мы лишь кратко опишем, как они устроены и обучаются. Основная форма искусственных нейронных сетей, 12 прямых нейронных сетей, представляют собой параметризованные математические функции  $y = f(x; \theta)$ , которые преобразуют входные данные  $x$  в выходные данные  $y$ , применяя их посредством серии нелинейных преобразований:  $f(x) = (f_n \circ \dots \circ f_1)(x)$ . Здесь каждый компонент  $f_k$ , называемый сетевым уровнем, состоит из простого линейного преобразования выходного сигнала предыдущего компонента, за которым следует нелинейная функция:  $f_k = \sigma_k(\theta_k T f_k - 1)$ . Нелинейные функции  $\sigma_k$  обычно являются сигмоидальными функциями или направляющими, как описано ниже, а  $\theta_k$ -матрицами чисел, называемыми весами модели. На этапе обучения обучающие данные поступают в сеть, и задача состоит в том, чтобы делать прогнозы на выходном уровне, соответствующие известным меткам, и каждый сетевой компонент соответствующим образом представляет свои входные данные. Он должен научиться наилучшим образом использовать промежуточные представления для формирования сложного иерархического представления данных, заканчивающегося правильными прогнозами на выходном уровне. Обучение нейронной сети означает изменение ее веса для оптимизации выходных данных сети. Это делается с помощью алгоритма оптимизации, называемого градиентным спуском, для функции измерения точности выходных данных, называемой функцией затрат или функцией потерь. Основные идеи, лежащие в основе обучающих нейронных сетей, просты: по мере прохождения обучающих данных по сети вычисляйте градиент функции потерь относительно каждого веса, используя правило цепочки, и уменьшайте потери, изменяя эти веса с помощью градиентного спуска. Но человек сразу же сталкивается с огромными вычислительными трудностями, когда сталкивается со сложными сетями с тысячами или миллионами параметров и экспоненциальным числом путей между узлами и выходом сети. Методы, предназначенные для преодоления этих проблем, становятся довольно сложными. Подробное описание методов и практических вопросов, связанных с обучением нейронных сетей, смотрите в [216] [218].

Искусственные нейронные сети часто изображаются в виде сети узлов, как показано на рис. 2.6.

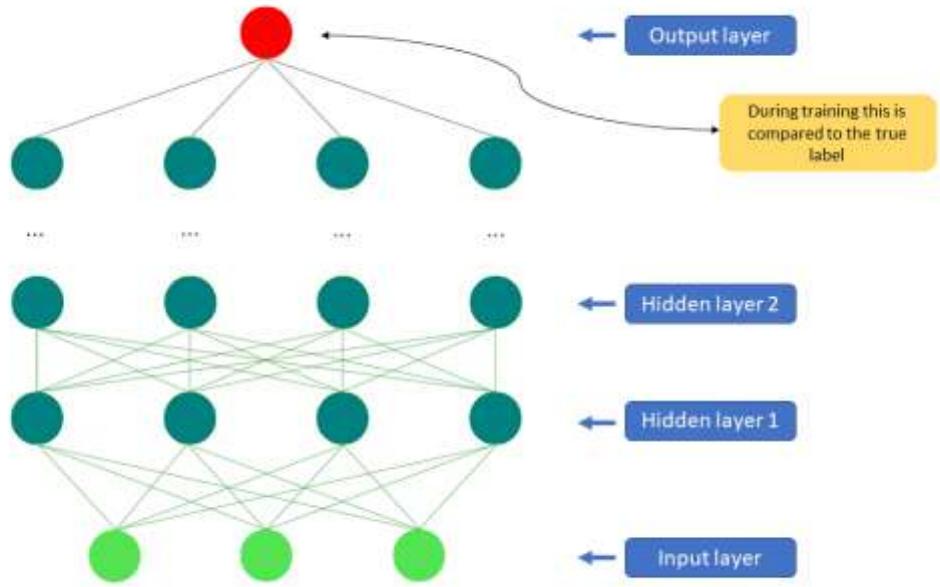


Рисунок 2.6. Искусственные нейронные сети строятся из простых линейных функций, за которыми следуют нелинейности

Одним из простейших классов нейронных сетей является многослойный персептрон, или прямая нейронная сеть, которая возникла в результате работы Розенблатта в 1950-х годах [219]. Она основана на простых вычислительных единицах, называемых нейронами, организованными слоями. Записывая  $i$  для  $I$ -го слоя и  $j$  для  $j$ -го блока этого слоя, выходные данные  $j$ -го блока на  $I$ -м слое равны  $z_j(i) = \theta_j(i) T x$ . Здесь  $x$  состоит из выходов из предыдущего слоя после того, как они подаются через простую нелинейную функцию, называемую функцией активации, обычно сигмовидную функцию  $\sigma(z) = 1 / (1 + e^{-z})$  или выпрямленную линейную единицу  $ReLU(z) = \max(0, z)$  или ее малую вариацию. Следовательно, каждый слой вычисляет взвешенную сумму всех выходных сигналов нейронов предыдущих слоев, за которыми следует нелинейность. Это называется активацией слоя. Активация каждого уровня передается на следующий уровень в сети, который выполняет те же вычисления до тех пор, пока вы не достигнете выходного уровня, где делаются сетевые прогнозы. В конце концов, вы получаете иерархическое представление входных данных, где более ранние объекты, как правило, носят очень общий характер, становясь более конкретными по отношению к выходным данным. Отправляя в сеть обучающие данные, распределенные по уровням, сеть учится выполнять полезные задачи. Точка обучающих данных (или, как правило, небольшая партия обучающих точек) подается в сеть, выходные данные и локальные производные на каждом узле записываются, и разница между прогнозируемым результатом и истинной отметкой измеряется целевой функцией, такой как средняя абсолютная ошибка ( $L1$ ), среднеквадратичная ошибка ( $L2$ ), потеря перекрестной энтропии или потеря костной массы, в зависимости от применения. Производная целевой функции по отношению к выходному

сигналу вычисляется и используется в качестве сигнала обратной связи. Расхождение распространяется по сети в противоположном направлении, и все веса обновляются, чтобы уменьшить ошибку. Это достигается с помощью обратного распространения [220-222], которое вычисляет градиент целевой функции относительно масштабов в каждом узле, используя цепное правило наряду с динамическим программированием и градиентным спуском [223], алгоритмом оптимизации, разработанным для улучшения масштабов.

## 2.2 Глубокое обучение

Глубокое обучение - это метод машинного обучения, который учит компьютеры делать то, что естественно для человека: учиться на собственном примере. Модели глубокого обучения могут достигать высочайшей точности, иногда превышающей производительность на уровне человека. Модели обучаются с использованием большого набора помеченных данных и архитектуры нейронных сетей, содержащих много слоев. Термин "глубокий" обычно относится к количеству скрытых слоев в нейронной сети. Традиционные нейронные сети содержат всего 2-3 скрытых слоя, в то время как глубокие сети могут содержать до 150.

Традиционно модели машинного обучения обучаются выполнению полезных задач на основе разработанных вручную функций, извлеченных из необработанных данных, или функций, изученных другими простыми моделями машинного обучения. При глубоком обучении компьютеры изучают полезные представления и функции автоматически, непосредственно из необработанных данных, минуя этот ручной и сложный этап. Конечно, наиболее распространенными моделями глубокого обучения являются различные версии искусственных нейронных сетей, но есть и другие. Основной общей характеристикой методов глубокого обучения является их ориентация на изучение атрибутов: автоматическое изучение представлений данных. Это основное различие между подходами к глубокому обучению и более "классическим" машинным обучением. Обнаружение признаков и выполнение задачи объединяются в одну задачу, и, следовательно, обе улучшаются в ходе одного и того же процесса обучения. Общие обзоры этой области см. в [227] [228].

В медицинской визуализации интерес к глубокому обучению в основном обусловлен сверточными нейронными сетями (CNNs) [229], мощным способом изучения полезных представлений изображений и других структурированных данных. До того, как стало возможным эффективно использовать CNNs, эти функции, как правило, приходилось разрабатывать вручную или создавать с использованием менее мощных моделей машинного обучения. Как только стало возможным использовать функции, полученные непосредственно из данных, многие из созданных вручную функций изображения вообще остались в стороне, поскольку они были практически бесполезны по сравнению с детекторами функций, найденными CNNs. В CNN встроены некоторые сильные предпочтения, основанные на том, как они построены, что помогает нам

понять, почему они такие сильные. Итак, давайте взглянем на строительные блоки CNN.

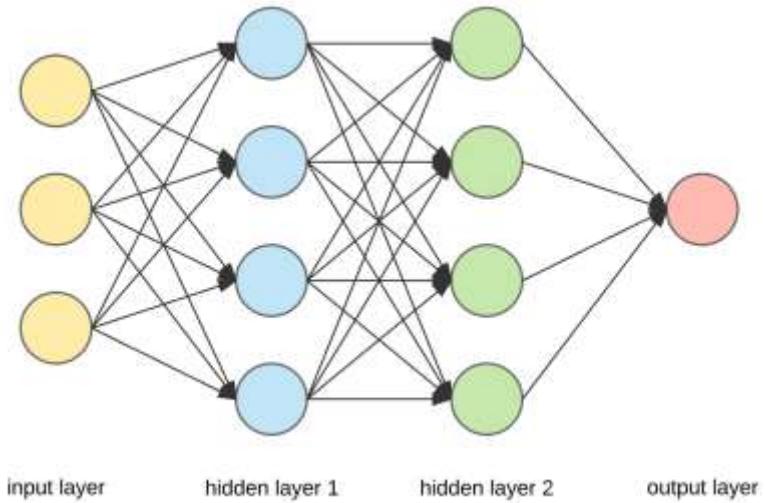


Рисунок 2.7 Глубокое обучение

### 2.2.1 Сверточная нейронная сеть

Искусственные нейронные сети (ИНС) приобрели популярность в обработке неструктурированных данных за последние годы, включая изображения, текст, звук и речь. Сверточные нейронные сети (СНС) показывают отличные результаты при обработке таких неструктурированных данных. В случаях, когда с данными связана топология, сверточные нейронные сети успешно извлекают признаки из предоставленного набора данных. Архитектурно СНС вдохновлены многослойными нейронными сетями (МНС). Установливая локальные ограничения на связь между нейронами соседних слоев, СНС используют локальную пространственную корреляцию. Основным элементом СНС является обработка данных через операцию свертки. Свертка любого сигнала с другим сигналом создает третий сигнал, который может раскрывать больше информации о сигнале, чем сам исходный сигнал.

Сверточные нейронные сети основаны на свертке изображения и обнаруживают признаки на основе фильтров, которые изучаются СНС в процессе обучения. Например, для обнаружения болезни или удаления гауссовского шума мы не применяем известные фильтры, а используем сверточную нейронную сеть для обучения. Алгоритм сам изучает фильтры обработки изображений, которые могут значительно отличаться от традиционных фильтров обработки изображений. Для обучения с учителем фильтры изучаются так, чтобы общая функция стоимости была минимальной. Обычно первый слой свертки учится обнаруживать наличие инсульта, в то время как второй слой может учиться обнаруживать более сложные формы, образуемые различными типами инсульта, такими как ишемический, геморрагический и так далее. Третий слой и последующие изучают намного более сложные объекты на основе тех, что были созданы в предыдущем слое. Одной из фундаментальных особенностей сверточных нейронных сетей является разреженная связность, возникающая из-за весового обмена, что значительно уменьшает количество параметров, подлежащих обучению. Тот же

самый фильтр может учиться обнаруживать одинаковые края в любой части изображения из-за свойства эквивариантности, которое является отличным свойством свертки, полезным для обнаружения объектов.

Вот ключевые компоненты сверточной нейронной сети:

Типичные компоненты сверточной нейронной сети перечислены ниже:

Интенсивность пикселей изображения будет сохранена во **входном слое**. Для красного, зеленого и синего цветовых каналов (RGB) входное изображение шириной 64, высотой 64 и глубиной 3 будет иметь входной размер 64x64x3.

**Слой свертки** берет изображения из предыдущих слоев и свертывает их с помощью указанного количества фильтров для создания отображений выходных объектов. Указанное количество фильтров равно количеству отображений выходных объектов. CNN от TensorFlow или PyTorch до сих пор в основном использовали 2D-фильтры, однако только что были добавлены 3D-фильтры свертки.

**Функциями активации** для CNN обычно являются ReLUs. После прохождения уровней активации ReLU выходное измерение совпадает с входным значением. Уровень ReLU придает сети нелинейность, а также обеспечивает ненасыщенные градиенты для положительных входных сигналов сети.

Что касается высоты и ширины, объединяющий слой уменьшит размерность 2D-карт активации. Глубина или количество **карт активации** не изменяются и остаются постоянными.

Традиционные нейроны в **полностью связанных слоях** получают различные наборы весов из предыдущих слоев; в отличие от процессов свертки, между ними нет разделения весов. Благодаря независимым весам каждый нейрон в этом слое будет связан со всеми нейронами в предыдущем слое или со всеми координатными выходами в выходных картах. Выходные нейроны класса получают входные данные от конечных полностью связанных слоев для классификации.

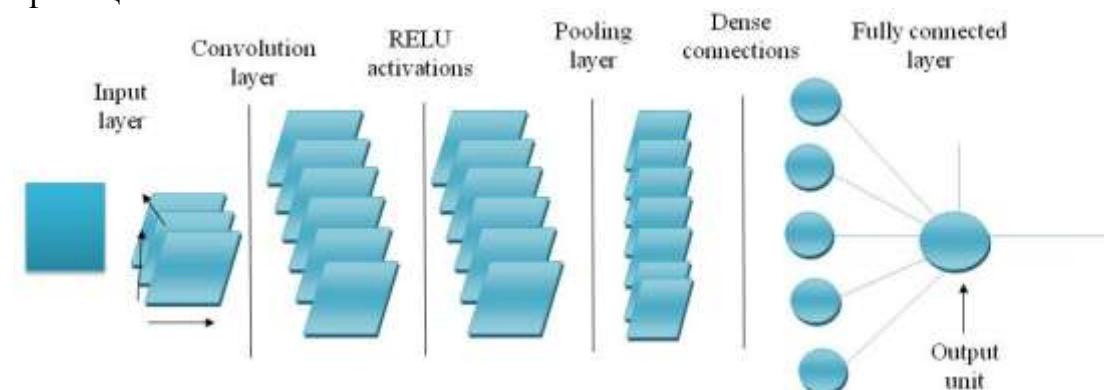


Рисунок 2.8 Базовая структурная схема сверточной нейронной сети

На рисунке 2.8 показана базовая сверточная нейронная сеть, которая использует один сверточный слой, один слой ReLU и один ассоциативный слой, за которым следует полностью связанный слой и, наконец, выходной слой классификации. Сеть пытается отличить изображения мозга с инсультом от

изображений здорового мозга. Устройство вывода можно рассматривать как сигмовидную функцию активации, поскольку это проблема классификации двоичных изображений. Как правило, для большинства архитектур CNN комбинации сверточных слоев с несколькими уровнями ReLU складываются одна за другой перед полностью унифицированными слоями [233].

### 2.2.2 U-Net

U-Net - это тип сверточной нейронной сети (CNN), которая была разработана для сегментации биомедицинских изображений. Впервые он был представлен в статье Олафа Роннебергера, Филиппа Фишера и Томаса Брокса в 2015 году, специально для удовлетворения потребности в более точной сегментации в медицинской визуализации.

Вот некоторые ключевые функции и характеристики U-Net:

1.Архитектура: U-Net имеет отличительную архитектуру, напоминающую букву "U", от которой она и получила свое название. Он состоит из сокращающегося пути (downsampling), который фиксирует контекст изображения, и расширяющегося пути (upsampling), который обеспечивает точную локализацию.

2.Сокращающийся путь: Сокращающийся путь аналогичен типичной сверточной сети. Он состоит из повторного применения сверток, за которым следует выпрямленная линейная единица измерения (ReLU) и операция максимального объединения для понижающей дискретизации. Каждый шаг понижающей дискретизации увеличивает количество функциональных каналов.

3.Расширяющийся путь: Расширяющийся путь сочетает в себе высокоуровневые функции, изученные в сокращающемся пути, с пространственной информацией для обеспечения точной локализации. Это включает в себя повышающую дискретизацию карты объектов, за которой следует свертка ("up-convolution"), которая уменьшает вдвое количество каналов объектов, объединение с соответствующим образом обрезанной картой объектов из сокращающегося пути и еще две свертки, за каждой из которых следует ReLU.

4.Пропуск соединений: Ключевой особенностью U-Net является использование пропускаемых соединений. Эти соединения используются для объединения карт объектов из пути понижающей дискретизации с картами из пути повышающей дискретизации, что помогает восстановить пространственный контекст, потерянный во время понижающей дискретизации.

5.Заключительный слой: На заключительном слое используется свертка 1x1 для сопоставления каждого вектора объектов с желаемым количеством классов.

6.Применение в сегментации биомедицинских изображений: U-Net был специально разработан для сегментации медицинских изображений, где доступность данных часто ограничена и высока потребность в точной

сегментации. Его эффективность в этой области была хорошо продемонстрирована, что делает его популярным выбором для таких задач, как сегментация опухолей, определение границ органов и т.д.

7. Адаптивность: Хотя изначально U-Net разрабатывался для биомедицинской визуализации, он был адаптирован для различных других задач сегментации изображений за пределами медицинской визуализации, демонстрируя свою универсальность и эффективность.

Конструкция U-Net позволяет эффективно использовать данные и выполнять точную сегментацию, что имеет решающее значение в медицинской визуализации, где размеры наборов данных часто невелики, а требования к точности высоки. Его способность улавливать контекст и подробную информацию о локализации делает его мощной моделью для задач сегментации.

Таким образом, архитектура U-Net позволяет ей захватывать как контекст (с помощью сокращающегося пути), так и локализацию (с помощью расширяющегося пути), что делает ее высокоэффективной для таких задач, как сегментация изображений, особенно в биомедицинских приложениях. На рисунке 2.9 показана Базовая архитектура U-Net.

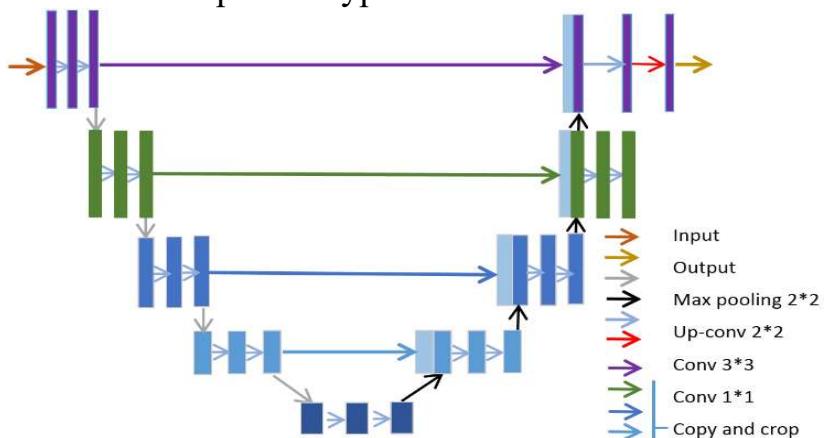


Рисунок 2.9 Базовая архитектура U-Net

## 2.3 Обнаружение инсульта

При подозрении на инсульт немедленная диагностика и лечение действительно очень важны, поэтому, если инсульт действительно произошел, можно начать лечение, чтобы спасти как можно больше мозговой ткани. Итак, каковы этапы диагностики? Прежде всего, медицинская бригада как бы опрашивает пациента о его симптомах и проводит некоторые физические осмотры. И это для того, чтобы проверить неврологическую систему пациента, чтобы найти какой-либо компромисс из-за инсульта. Но чрезвычайно важной частью диагностики инсульта является проведение визуальных тестов, позволяющих по-настоящему взглянуть на мозг и увидеть, что там происходит. Одними из наиболее распространенных и важных являются компьютерная томография или МРТ, которые, по сути, представляют собой особый тип рентгеновского снимка, который позволяет получать различные изображения с разных уровней и ракурсов.

Среди работ, использующих изображения КТ и МРТ, исследователи [143] [144] оценили полезность итеративной реконструкции модели (IMR-Neuro) в диагностике инсульта по изображениям КТ. IMR-Neuro сравнивается с отфильтрованной обратной проекцией (FBP). Оба метода были применены к базе данных из 40 КТ-исследований, 20 контрольных пациентов и 20 пациентов с ишемическим инсультом, подтвержденным с помощью МРТ с диффузионно-взвешенным изображением (ДВИ), известной как МРТ-ДВИ, в течение 24 часов после КТ. Авторы сравнили результаты работы 10 рентгенологов по выявлению гипоаттенуации паренхиматозных реконструкций двумя методами с использованием ROC-кривых и теста jackknife. Статистический анализ результатов показал, что IMR-Neuro значительно снижает шум изображения и увеличивает отношение контрастности к шуму (CNR) зоны инфаркта, повышая эффективность наблюдателя при обнаружении области гипоаттенуации. Однако исследование имеет следующие ограничения: использование небольшой базы данных, что ограничивает обобщение результатов; область миокарда была подтверждена исследованиями МРТ-ДВИ, полученными в течение 24 часов после КТ, и, следовательно, существовала возможность прогрессирования или изменения с момента проведения КТ; а также трудность определения ROI в островке сердечного приступа, которая зависит только от анализа специалиста.

Компьютерная томография без контрастирования является высокоэффективным методом диагностики, поскольку позволяет провести предварительный анализ, который позволяет быстро исключить состояния, которые могут показаться похожими на инсульт. Однако плотность области паренхимы головного мозга, пораженной инсультом, очень похожа на незатронутую область. Это чрезвычайно затрудняет дифференциацию раннего сердечного приступа у людей. В связи с этим контрастная характеристика ишемического инсульта по отношению к нормальной паренхиме головного мозга на неконтрастных КТ-изображениях была описана в работе [145]. Авторы использовали базу данных из 519 исследований 429 анонимных пациентов с клинически подтвержденным инсультом. Исследование проводилось в рамках стандартной процедуры диагностики инсульта в отделении неотложной помощи и во время стационарного лечения. Эти исследования были получены с использованием четырех различных приборов для компьютерной томографии в двух больничных центрах в Кракове и Жешуве, Польша. Более эффективно сердечные приступы характеризовались средними значениями 8,28 HU (единицы Хаунсфилда), 6,60 HU и 7,55 HU, рассчитанными как разница в 5 последовательных вокселях, относящихся к поражению и паренхиме, между всеми исследованиями. Результаты показали сложность ручной или автоматической сегментации мазков в неконтрастных тестах, основанных только на методах HU или гистограммы, независимо от времени проведения мазка. Это показывает, что данная область исследований довольно сложна и открыта для новых исследований в области методов обнаружения и сегментации на неконтрастных КТ-изображениях с улучшенным разрешением.

Большинство исследований компьютерной томографии фокусируются только на одном типе поражения. В попытке преодолеть эту ситуацию [146] была разработана система обнаружения с использованием сверточных нейронных сетей (CNNS), оптимизированная с помощью оптимизации роя частиц (PSO). Лишь в нескольких исследованиях использовались естественные и метаэвристические методы оптимизации CNN, имеющие дело только с параметрами CNN (т.е. весами и смещениями), а не с их гиперпараметрами (т.е. скоростью обучения, импульсом и потерей веса). В дополнение к этим материалам авторы предоставили базу данных компьютерных изображений, состоящую из 25 исследований, полученных с использованием компьютерной томографии GE Medical System HiSpeed, которые были получены при поддержке клиники Траяно Алмейда -Клиники диагностической визуализации, Форталеза-СЕ, Бразилия. Некоторые изображения были отброшены из-за низкого качества, в результате чего было получено 300 изображений, состоящих из 100 нормальных изображений и 200 изображений с инсультом (100 геморрагических и 100 ишемических), которые содержали неправильные узоры, нерегулярное освещение и различные структурные характеристики. Эксперименты проводились с архитектурами ImageNet и CIFAR-10, а также с разделением базы данных (обучение/тестирование) на 50/50 и 75/25 соответственно. Эксперименты с протоколом 75/25 и архитектурой CIFAR-10 дали наилучшие результаты с точностью, близкой к  $98,86 \pm 0,65$ . Важным результатом этого подхода стала правильная классификация пациентов с инсультом, то есть ни один пациент с ишемией не был классифицирован как здоровый или с геморрагией. Из числа здоровых людей лишь немногие были классифицированы как пациенты с геморрагией. Однако некоторые пациенты с геморрагией были классифицированы как ишемические, но ни один пациент с геморрагией не был классифицирован как здоровый. Однако авторы намерены найти другие альтернативы для улучшения результатов, в том числе путем расширения баз данных и тестирования различных методов глубокого обучения, таких как сети глубоких убеждений. Авторы заявляют, что эта работа может послужить основой для других исследовательских работ, поскольку набор данных, представленный в этой статье, теперь находится в открытом доступе. Только в двух статьях использовались МРТ-снимки для выявления инсульта. [147] использовали МРТ-изображения для выявления инсульта, и в этом исследовании классификаторы k-ближайшего соседа (kNN) и минимального среднего расстояния (MMD) использовались для выявления геморрагических инсультов. Классификаторы были протестираны в базе данных, состоящей из 50 МРТ-изображений различных пациентов с тремя конфигурациями показателей расстояния: евклидовым, суммарным и максимальным. Результаты показали, что CIU превосходит MMD в выявлении и количественной оценке площади геморрагических инсультов и что лучшим показателем расстояния для двух классификаторов является максимальное расстояние. В работе [148] авторы предложили метод, сочетающий в себе преимущества неконтролируемых и контролируемых методов. В частности,

неконтролируемый компонент обнаруживает поврежденное полушарие, выполняет энантиоморфную нормализацию 2 и строит карту вероятности повреждения (LPM), используя конвейер нечеткой кластеризации (FCP). Затем CVL используются для построения многомерного воксельного вектора признаков, который предоставляет анатомическую / пространственную информацию, увеличивающую различие между поражениями и здоровыми тканями. Контролируемый компонент использовал вектор признаков для обучения комбинации классификаторов reference vector machine (SVM) для окончательного обнаружения поражения. Для проверки предложенной системы авторы протестировали метод, используя 60 изображений МРТ различных пациентов. Используя перекрестную валидацию без исключения, предложенный метод позволил достичь среднего коэффициента сходства костей (DSC) в 73,1% по сравнению с ручными подходами обученных неврологов. Кроме того, они протестировали с использованием набора данных BRCA-2012 MICCAI, достигнув среднего значения DSC в 66,5%. Кроме того, с этими двумя наборами тестовых данных предложенный метод показал конкурентоспособные результаты по сравнению с тремя современными методами ([149], [150], [151]). Выявление и анализ повреждения головного мозга вследствие инсульта может помочь понять взаимосвязь между повреждением и дефицитом, предсказать диагноз и прогноз пациента, а также отследить развитие церебральной патологии с течением времени.

[152] представлена структура Интернета вещей (IoT) для классификации инсульта в соответствии с компьютерными изображениями с использованием сверточных нейронных сетей (CNN) для идентификации здорового мозга, ишемического инсульта или геморрагического инсульта. Следуя концепции трансферного обучения, CNN был объединен с различными консолидированными методами машинного обучения, такими как байесовский классификатор, многослойный персепtron, k-ближайший сосед, случайный лес и машины опорных векторов. Наш подход способствует автоматизации диагностического процесса с помощью компетентного метода, который способен получать информацию, невидимую человеческому глазу, и тем самым способствует более точному диагнозу. Кроме того, с появлением Интернета вещей появляется новый высокоэффективный и гибкий инструмент для решения вопросов, связанных с медицинскими услугами, и именно в рамках нашего подхода мы можем обеспечить удаленную диагностику и мониторинг пациентов. Подход был подтвержден путем анализа параметров accuracy, F1-точки, отзыва, точности и времени обработки. Результаты показали, что CNN получил 100% точность, F1-балл, отзыв и аккуратность в сочетании с большинством протестированных классификаторов. Наименьшее время обучения и тестирования составило 0,015 С и 0,001 с, соответственно, в сочетании с байесовским классификатором. Таким образом, наш подход демонстрирует эффективность и надежность обнаружения инсульта.

Некоторые стареющие страны изучают факторы риска инсульта, чтобы помочь людям предотвратить его. [153] изучают факторы и заболевания,

которые возникают до инсульта, как особенности выявления инсульта и поиска аффективных факторов инсульта. Выявление инсульта исследуется на основе обучающих классификаторов, SVM, Naïve Bayes, KNN и дерева решений. Кроме того, Chi2 используется для поиска аффективных факторов инсульта. Четыре наиболее аффективных фактора инсульта необходимы для определения риска инсульта. Авторы утверждают, что эти факторы более эффективны для выявления инсульта, чем болезни, и дерево решений является лучшим классификатором. Дерево решений дает 72,10% точности и 74,29% F-показателей. Факторами, влияющими на инсульт, являются курение, алкоголь, уровень холестерина, кровяное давление, секс, физические упражнения и профессия. Более того, авторы обнаружили, что отказ от курения может предотвратить инсульт. Потребление алкоголя, повышенный уровень холестерина и повышенное кровяное давление увеличивают риск инсульта.

В [154] авторы используют модели машинного обучения для улучшения методов классификации уровня риска инсульта в рамках Национального скрининга инсульта в Китае. Во-первых, авторы создают обучающий набор и наборы тестов и обрабатывают обучающий набор дисбаланса на основе метода избыточной выборки и отсутствия выборки. Затем разработайте девять моделей машинного обучения (модель логистической регрессии, наивная байесовская модель, байесовская сетевая модель, модель дерева решений, модель нейронной сети, модель случайногого леса, модель мешковатого дерева решений, модель голосования и модель улучшения с деревьями решений) для классификации уровней риска инсульта с использованием данных национального скрининга инсульта за 2017 год. В результате они добились самого высокого уровня отзыва (99,94%), применив модель с деревом решений, а точность модели, основанной на случайному лесу, является самой высокой (97,33%). Используя модель случайногого леса (отзыв: 98,44%), отзыв будет увеличен примерно на 2,8% по сравнению с используемым в настоящее время методом, и каждый год можно будет выявлять еще несколько тысяч человек с высоким риском инсульта.

Определение типа инсульта как можно раньше имеет решающее значение, поскольку неправильное или несвоевременное лечение может привести к летальному исходу [155] [156]. Обнаружение и локализация зависят от магнитно-резонансной томографии (МРТ) и, чаще всего, от компьютерной томографии (КТ). Хотя и МРТ, и КТ являются точными и надежными методами, ни один из них не является по-настоящему портативным и, следовательно, готовым к широкому использованию в машине скорой помощи для выявления инсультов на как можно более ранней стадии. Кроме того, МРТ стоит дорого, а компьютерная томография связана с риском для здоровья из-за ионизирующего излучения [157]. Эти проблемы стимулируют разработку альтернативных подходов, которые должны быть быстрыми, безопасными, портативными и экономически эффективными.

Микроволновая визуализация (MVI) способна обеспечить эти преимущества и, таким образом, стала многообещающей альтернативой для

диагностики инсульта, которую можно использовать перед МРТ или компьютерной томографией [158]. Среди большого количества исследований в области медицинской микроволновой визуализации, которые из-за обширности темы не могут быть полностью рассмотрены здесь, мы отмечаем, что были разработаны различные экспериментальные системы для мониторинга и выявления инсульта [159] [160] [161]. Прототипы, основанные на машинном обучении, также были разработаны и клинически протестированы [162] [163]. Что касается микроволновой визуализации, в частности для визуализации головного мозга, то исследование Хопфера и соавт. использование микроволнового сканера из 177 антенн позволило получить успешные результаты экспериментальной реконструкции для обнаружения инсульта и мониторинга мозга [164]. Кроме того, в литературе [165] и [166] проанализирована конструкция сканера микроволновой томографии (МВТ) для визуализации головного мозга с целью определения соответствующих частот и свойств среды связи, а также оптимизации конструкции антенной решетки.

Хотя одно из первых упоминаний о микроволновом детекторе геморрагического инсульта можно найти в патенте США изобретателей Хаддада и Требса [167], в настоящее время существует несколько исследовательских групп, работающих над системами раннего выявления и дифференциации инсульта. Достаточно назвать нескольких руководителей групп, активно работающих в этой области, чтобы понять масштаб исследований — Майкл Перссон из Medfield Diagnostics AB, Швеция [168], Сергей Семенов из EMTensor GmbH, Австрия [169], Лоренцо Крокко из Национального исследовательского совета Италии, Италия [171] [172] [173]. Подробный обзор можно найти в [174]. В целом, в специальной литературе можно найти два различных подхода к идентификации и классификации штрихов: методы, основанные на визуализации, то есть реконструкции изображения, распределении диэлектрических параметров в интересующей области [171, 175] и методы, основанные на алгоритмах машинного обучения [164] [176] [177]. Сравнение между статьями в этом подразделе кратко представлено в таблице 2.1

Таблица 2.1: Исследования по обнаружению инсульта

Исследование	Тип инсульта	Тип иссл.	Тип базы данных	Оценочные показатели	Технология	Тип обнаружения
(Inoue и др., 2017) [143]	и	КТ	Част	RХП	IMR-Neuro, FBP	Эффективность обнаружения гипо-затухания
(Iyama и др., 2017) [144]	и	КТ	Част	RХП, Складной нож	IMR-Neuro, FBP	Автоматический
Gomolka и др. [145]	и	ЧПУ-КТ	Част	Количественный	Шкала HU	изображения ЧПУ-КТ
Pereira и др. [146]	и и г	КТ	Общ	Точность, матрица неточностей	CNN+PSO	Снимки компьютерной томографии

Sudharani и др. [147]	г	MPT	Част	Количественный	K-NN, MMD	новый алгоритм, использующий программное обеспечение LabVIEW
Guo и др. [148]	Хронический ишемический инсульт	T1-взвешенная 3D-MPT	Част	эффективность метода обнаружения повреждений с использованием стратегии перекрестной проверки "без исключения"	SVM	новый метод автоматического выявления поражений головного мозга с помощью 3D-MPT, взвешенной по T1
Carlos и др., 2019 [152]	и или г	КТ	Част	Количественный	CNN+ BC, MP, k-NN, RF, SVM	Комбинация КТ с байесовским классификатором
Li и др., 2019 [154]	и	MPT	Общ	RХП	LR, NB, BN, DT, NN, RF, BDT	Алгоритмы ML
Karadima и др., 2020 [156]	и и г	Сверхвысокочастотный	Част	Диэлектрические свойства	8-портовый VNA, 8 антенн, DBIM-TwIST	прототип микроволновой томографии
Chandra и др., 2015 [158]	и или г	Сверхвысокочастотный	Част	Количественный	Метод Ньютона	Клинические испытания
Tobon Vasquez и др., 2019 [159]	г	Сверхвысокочастотный	Част	матрица рассеяния	Кольцо, коммутационная матрица, соединительная среда	прототипы микроволновых систем
Merunka и др., 2019 [161]	г	Сверхвысокочастотный	Част	полная S-матрица	держатель антенной решетки, фантом человеческой головы, Гаусс-Ньютон	прототип лабораторной микроволновой системы визуализации
Persson и др., 2014 [162]	и и г	Сверхвысокочастотный	Част	Моделирование	шлем, методы обработки сигналов	данные микроволновых измерений
Scapaticci и др., 2014 [172]	и и г	Сверхвысокочастотный	Част	информация о конкретном пациенте	приблизительный эталонный сценарий	Двумерная антропоморфная модель головы
Abbosh и др., 2013 [175]	и и г	Сверхвысокочастотный	Част	S-параметры частотной области	Микроволновая система, алгоритм статистического классификатора	инструменты клинической визуализационной диагностики
Salucci и др., 2017 [176]	и или г	Сверхвысокочастотный	Част	Экспериментальный	SVM, LBE	бинарная классификация

## 2.4 Классификация инсульта

За последние два десятилетия произошло быстрое развитие логических и клинических достижений, в основном благодаря использованию нейровизуализации, включая визуализацию с привлекательной реверберацией (МРТ) [208], компьютерную томографию (КТ) [209] и позитронно-разрядную томографию (ПЭТ) [210].

ПЭТ-томография предоставляет полезные метаболические и атомарные данные на клеточном уровне и в настоящее время является самым качественным клиническим методом оценки церебральной гемодинамики и состояния пищеварительной системы. В качестве высокочувствительного метода визуализации ограничение наномолярной конвергенции радиоактивно меченого органического атома, называемого индикаторами, осуществляется за счет соответствующего расположения гамма-лучей, возникающих в результате уничтожения позитронов. Эти показатели могут быть использованы для количественной оценки различных гемодинамических и метаболических процессов, важных для анализа инсульта, включая мозговой кровоток (CBF), объем мозговой крови (CBV) и скорость кислородного обмена в головном мозге (CMRO<sub>2</sub>) [211]. ПЭТ вообще недоступна и не является полезной системой для лечения интенсивного инсульта. Более простые и доступные методы включают компьютерную томографию (КТ) или магнитно-резонансную томографию (МРТ) с перфузионной визуализацией.

Ишемический инсульт у пациентов, обследованных с помощью КТ и МРТ, показан на рис.2.10. Компьютерная томография при анализе ишемического инсульта

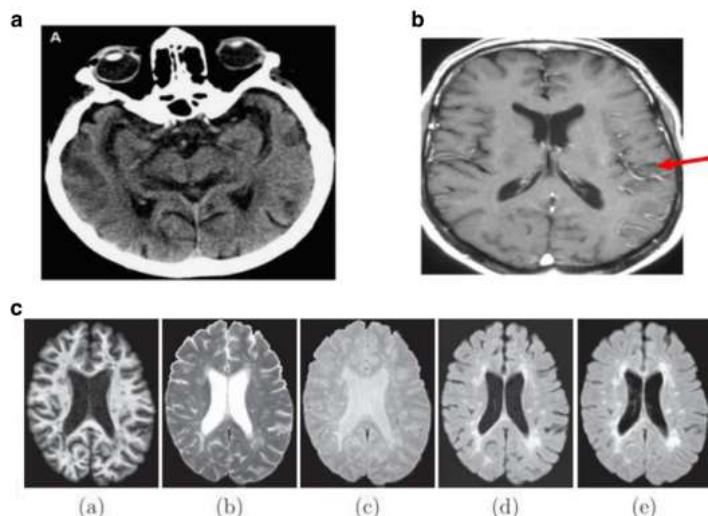


Рисунок 2.10. Необлученная компьютерная томография с транзиторными ишемическими атаками в левой половине тела. б. Изображение МРТ с транзиторными ишемическими атаками в правой части тела. в. входное изображение с синтетическими изображениями и изображениями с инверсионным восстановлением (FLAIR), ослабленными жидкостью

[214] использовали текстурные характеристики, а не характеристики интенсивности, для классификации типа инсульта на КТ-изображениях головного мозга. Система состоит из предварительной обработки, при которой удаляются кости черепа и извлекаются текстурные характеристики области.

Следующие шаги очертить область, на которую влияет штрих, и проанализировать характеристики с помощью классификатора SVM. Классификатор был реализован с тремя функциями ядра (линейной, квадратичной и RBF), чтобы определить подходящий вариант для обнаружения и классификации штрихов. Авторы использовали свою собственную базу данных для проверки предложенного метода, который не является общедоступным, но включает в себя компьютерную томографию пациентов различных возрастных групп. Используя три ядра, этот метод позволил получить более 80% результатов ACC. Наиболее многообещающие результаты были получены при использовании линейного ядра с 92% TPR, 89% SPC и 91% ACC. Оценка предложенного подхода подтверждает его эффективность и надежность, однако этот подход следует оценивать на более крупных базах данных. Использование больших и разнообразных наборов компьютерной томографии должно повысить производительность системы и обеспечить повторяемость результатов. [215] разработано решение, основанное на текстурном анализе, для распознавания тканей после инсульта на КТ-снимках. Предлагаемый метод состоит из двух этапов: сегментации областей, представляющих интерес, и классификации областей обводки путем извлечения различных атрибутов. Предлагаемое решение использует несколько числовых дескрипторов в областях Фурье 2D, Фурье 2D-полярных и многомасштабных (т.е. вейвлет, комплексный вейвлет и контурная область) областях. Результаты показали эффективность сегментации инсульта. Авторы не описывают и не предоставляют доступ к используемой базе данных. Экспериментальные результаты были близки к 75%, использованные случаи ранее были оценены рентгенологами со средним значением ACC 61,0% (в диапазоне от 47 до 84%), TPR 56% (в диапазоне от 40 до 81%), SEC 92% (в диапазоне от 66 до 100%) и 97% ACC (диапазон от 91 до 100%). Сравнивая результаты анализа, проведенного на основе пластиря, и рентгенологов, можно сделать вывод, что поставить диагноз непросто, но разработанный метод расширяет спектр полезных ресурсов и классификаторов, известных для выявления и дифференциации инсульта при компьютерной томографии.

От сердечно-сосудистых заболеваний головного мозга (CCMT) ежегодно страдают около 16 миллионов человек во всем мире. CCMT, также известный как инсульт, является серьезной глобальной проблемой здравоохранения и может привести к значительным физическим нарушениям у пострадавших. Компьютерная томография является наиболее подходящей процедурой для диагностики и оценки размера и амплитуды инсульта. Таким образом, в этой статье мы представляем структуру Интернета вещей (IoT) для классификации инсульта по компьютерным изображениям с использованием сверточных нейронных сетей (CNN) для идентификации здорового мозга, ишемического инсульта или геморрагического инсульта. Следуя концепции трансферного обучения, CNN был объединен с различными консолидированными методами машинного обучения, такими как байесовский классификатор, многослойный персепtron, k-ближайший сосед, случайный лес и методы опорных векторов.

Наш подход способствует автоматизации диагностического процесса с помощью компетентного метода, который способен получать информацию, невидимую человеческому глазу, и тем самым способствует более точному диагнозу. Кроме того, с появлением Интернета вещей появляется новый высокоэффективный и гибкий инструмент для решения вопросов, связанных с медицинскими услугами, и именно благодаря нашему подходу мы можем обеспечить удаленную диагностику и наблюдение за пациентами. Подход был подтвержден путем анализа параметров accuracy, F1-балла, recall, точности и времени обработки. Результаты показали, что CNN получил 100%-ную точность, F1-балл, recall и безошибочность в сочетании с большинством протестированных классификаторов. Самое короткое время обучения и тестирования составило 0,015 С и 0,001 с, соответственно, в сочетании с байесовским классификатором. Таким образом, наш подход демонстрирует эффективность и надежность обнаружения инсульта [216].

Отложение атеросклеротических бляшек, приводящее к снижению кровотока в сонных и коронарных артериях, приводит к цереброваскулярным (ишемический инсульт) и сердечно-сосудистым (инфаркт миокарда) событиям [217] [218]. В последние годы алгоритмы, основанные на ml, широко используются для оценки риска инсульта с использованием неинвазивных методов визуализации, таких как ультразвуковое исследование сонных артерий [219] [220] [221] [222] [223]. Нагрузка на атеросклеротические бляшки сонных артерий является важным биомаркером развития инсульта и может быть легко оценена с помощью визуализирующих тестов [224]. Появление КП на ультразвуковом изображении в режиме В (более яркое/гиперэхогенное/эхогенизированное или более темное/гипоэхогенное/эхопрозрачное) добавляет ценную информацию о профиле риска пациента [114]. Было показано, что эхо-прозрачная (более темная) атеросклеротическая бляшка (darker plaque) является потенциальным показателем развития инсульта [225]. Также было показано, что эффект этой эхо-прозрачной бляшки более выражен у пациентов с сахарным диабетом [226]. Аналогичным образом, однородный (более яркий) зубной налет из-за присутствия в нем кальция [227] [228] может быть признаком менее уязвимого зубного налета/бляшки с низким уровнем риска по сравнению с прозрачным налетом. Идентификация обоих этих фенотипов бляшек является важным шагом в оценке риска инсульта и может быть полезна при лечении стентированием или эндартерэктомией [229] [230] [231] [232]. Очевидно, что это решение является задачей классификации, для решения которой хорошо подходят системы на основе ml. В последнее десятилетие было предпринято много попыток автоматической классификации фенотипов СР [232] [233].

Ачарья и соавт. [234] представили исследования, в которых сонные артерии классифицировались как атеросклеротические бляшки с использованием алгоритма, основанного на контролируемом ml, такого как SVM и классификатор. Для обучения этих ml-систем мы использовали текстурные узоры, полученные с помощью ультразвуковых изображений

сонных артерий, а также статистические характеристики (среднее значение и стандартное отклонение). Авторы сообщили о 82,4% точности классификации с использованием классификатора на основе SVM. В 2013 году та же группа (Acharya et al. [235]) снова классифицировал фенотипы CR, используя комбинацию дискретного вейвлет-преобразования (DWT), HOS и текстурных признаков. С добавлением признаков DWT и HOS точность классификации возросла до 91,7%.

Выявление, правильная локализация и идентификация кровоизлияния в результате инсульта важны для постановки диагноза и определения лечения. В настоящее время разрабатывается несколько методов выявления и локализации геморрагического инсульта. Однако характеристика и классификация типа кровоизлияния все еще находятся на ранних стадиях разработки. [237] предложили алгоритм обнаружения и классификации геморрагического инсульта на КТ-изображениях головного мозга. Сначала выполняется предварительная обработка для удаления частей, которые могут снизить эффективность сегментации. На этапе сегментации была сконфигурирована модифицированная версия алгоритма эволюции набора уровней с регулировкой расстояния (DRLSE) в соответствии с приложением, чтобы можно было обнаружить наименьшие или более неопределенные кровоизлияния. Для повышения эффективности классификации был использован алгоритм оптимального выбора ресурсов, сочетающий генетический алгоритм (ha) и алгоритм Adaboost. Предлагаемый метод был представлен в базе данных с 627 изображениями, разделенными на 5 классов (эпидуральное кровоизлияние (EDH), субдуральное кровоизлияние (SDK), внутримозговое кровоизлияние (ВМС), внутрижелудочковое кровоизлияние (IVH) и нормальное кровоизлияние). Чтобы оценить атрибуты алгоритма выбора и классификатора SVM, был проведен сравнительный анализ с классификаторами MLP, KNN и SVM до и после использования алгоритма выбора ресурсов GA/Adaboost. На первом уровне класс VZHK был отделен от обычного класса, с которым acc составляет 92,46%, а на втором уровне три класса, локальные сети и SDH, EDH и ich, были классифицированы в соответствии с классификатором multiclass SVM, с которым acc составляет 94,13%. Время, затраченное на обработку каждого изображения, составило 15,57 секунды, что при реализации на C++ может быть сокращено как минимум в 20-30 раз. Несмотря на то, что были предложены различные методы сегментации и классификации опухолей головного мозга, совершенствование методов сегментации опухолей и мультиклассовая классификация по-прежнему являются сложными из-за сложных характеристик опухоли головного мозга, таких как большое разнообразие внешнего вида опухоли и неопределенность границ опухоли. Нааянан, А. et.al в 2019 году эта проблема была решена с помощью предложенного нового метода мультиклассовой классификации МРТ-изображений [239]. Наконец, классификация этих пяти типов опухолей головного мозга проводится с использованием мультиклассовой SVM. В этом SVM используется индивидуальный подход для многоклассовой

классификации. Моделирование в среде MATLAB выполняется для всех пяти типов классов с использованием графического интерфейса пользователя. Интерактивная CAD-система была разработана для поддержки специалиста-радиолога в многоклассовой классификации опухолей головного мозга. Зарчараки и другие. В 2017 году были проведены операции по удалению глиобластом, метастазов и мультиформных глиом. Точность, полученная для каждого класса, составила: 91,7% для метастазов, 90,9% для глиом низкой степени злокачественности и 41,2% для мультиформных глиобластом. Также была предложена классификация мультиклассовой модели сегментации опухолей головного мозга. По словам А. Патака, в 2014 году на заключительном этапе для мультиклассовых данных используется метод классификации, SVM. МРТ позволяет получить полное изображение нервных и мозговых тканей в нескольких плоскостях без каких-либо препятствий, включая кости. Кроме того, SVM - это классификация для распознавания множественных типов опухолей головного мозга в различных областях мозга с использованием автоматизированной поддержки.

Точное местоположение и протяженность инсульта важны для определения тяжести черепно-мозговой травмы. Однако разработать точный алгоритм выявления очагов инсульта сложно из-за различий в размерах, морфологической структуре и сходстве очагов поражения с нормальной паренхимой. [241] разработали автоматическую систему, основанную на оптимизации кластеризации, для быстрой и точной сегментации ишемического инсульта и классификации в соответствии с оксфордскими категориями: синдром частичного переднего кровообращения (PACS), лакунарный синдром (LACS) и общий инсульт переднего кровообращения (TACS). Алгоритм под названием DT-FODPSO сочетает в себе преимущества триангуляции Делоне (DT) и оптимизации дробных частиц Дарвина (FODPSO). Тесты проводились на базе данных из 192 МРТ-снимков, полученных с помощью аппарата Signa HDxt 1.5 Т Optima Edition (GE Healthcare, Ваукеша, Висконсин), изготовленного Институтом медицинских наук и больницей SUM в Бхубанешваре, штат Одиша, Индия. Изображения были предварительно обработаны с использованием фильтра Винера для повторного анализа шума, а затем был применен метод DT для определения поражения на основе распределения его интенсивности. Затем используется GLCM extractor, и извлеченные признаки применяются к классификаторам SVM и Random Forest (RF) для определения подтипа ишемического инсульта. На платформе Weka использовались классификаторы с 10-кратным подходом к исключению однократной и перекрестной проверки. Средний показатель ACC FODPSO составил 0,92, в то время как DT-FODPSO получил 0,94 при использовании классификатора SVM. При использовании RF-классификатора среднее значение ACC составило 0,93 и 0,95 при использовании FODPSO и DT-FODPSO, соответственно. Значения всех остальных измеренных параметров были лучше при использовании метода DT-FODPSO и RF-классификатора. При таком сочетании средний показатель TPR составил 0,94, JAC - 0,88 и DSC -

0,94. Предложенный метод был сравнен с другими 7 методами, использующими нечеткую кластеризацию, RF, naive Bayes и CNN, и показал, что DSC на 14% лучше, чем второй лучший метод. Метод DT-FODPSO оказался превосходным с точки зрения оцененных параметров и позволил идентифицировать множественные очаги поражения. Таким образом, предлагаемый метод способен более эффективно выявлять паттерны поражений при МРТ головного мозга по сравнению с другими описанными методами. Основным ограничением исследования является расчет объема эпицентра поражения, который может быть оценен по сегментарным поражениям в серии срезов одного и того же органа. [94] разработали метод определения наилучших методов улучшения МРТ для классификации внутримозговых кровоизлияний (ВМИ). В этом исследовании были проанализированы пять МРТ-исследований пациентов с диагнозом геморрагический инсульт, проведенных неврологическим отделением Университета Малайзии имени Пусата Перубатана Кебангсаана (PPUKM). Изображения были получены в формате DICOM и обработаны с использованием методов усиления контрастности, выравнивания гистограммы, повышения резкости изображения и медианного фильтра в программе MATLAB. Все изображения сравнивались на основе их абсолютной ошибки средней яркости (AMBE) и значений энтропии. Общие результаты показывают, что медианный фильтр был лучшим методом улучшения изображения со средними значениями амплитуды и энтропии 0,0885 и 5,14772 соответственно. Вторым лучшим методом было повышение резкости изображения и преобразование интенсивности по степенному закону с помощью гамма-коррекции. Выравнивание гистограммы не подходит для улучшения результатов МРТ, так как искажает изображения, значительно увеличивая их яркость. Недостатком этого исследования было использование очень ограниченной базы данных и исключение из нее любых пациентов с вторичным ВГГ, что препятствует обобщению результатов.

На первом этапе МРТ-изображения с опухолью классифицируются с использованием метода искусственной нейронной сети (ANN). PCA и искусственная нейронная сеть объединяются и называются подходом PCA-ANN, чтобы сделать систему более интеллектуальной. PCA используется для уменьшения размерности. Согласно Sachdeva et al., 2013, были проведены различные комбинации тестов для анализа эффективности предложенной системы (PCAANN) для классификации шести классов — пяти классов опухолей головного мозга и одного нормального класса. Удобная в использовании CAD-система была разработана для того, чтобы помочь рентгенологам в классификации опухолей головного мозга. Наряду с предложенной методологией, ограничения опухоли были отмечены с помощью СВАС, выделения фактора из SROI, отбора фактора с использованием PCA и модулей классификатора (ANN). Сравнительное исследование с методом ANN показало, что PCA-ANN повысил общую точность на 14%.

В 2016 году Сачдева и соавторы провели еще одну работу, связанную с гибридной моделью машинного обучения с использованием ANN /GA. В качестве входных данных для Ann были использованы несколько факторов. GA объединяет набор факторов, и группировка GA с ANN позволяет классифицировать даже те опухоли, которые похожи по размеру, форме, расположению, распространению и морфологии. Результаты эксперимента на исходном наборе данных показывают, что оптимизация с использованием подхода GA улучшила общую точность SVM с 79,4% до 91,6% и ANN с 75,5% до 94,8%. Аналогичным образом были получены результаты для вторичного набора данных. Совокупные результаты обоих подходов принесут пользу специалисту-радиологу, поскольку улучшат условия для классификации опухолей головного мозга.

Обнаружение опухоли головного мозга, которая представлена на медицинских изображениях, играет жизненно важную роль. Воздействие опухоли головного мозга зависит от области опухоли головного мозга, а также от ее размера, формы и границ [242]. Для выполнения этих обязательств были использованы методы обработки изображений с использованием Ann. Автор предложил два этапа, назвав их обработкой с использованием нейронных сетей (PWNN) и изображений (PWNN). Кроме того, для проведения методов визуализации, а также Ann и связанных с ними исследовательских подходов к обследованию пациентов с опухолями головного мозга. Результат основан на количественных данных, например, о размере, соотношении и форме пораженных клеток, основанных на их предыдущей работе (Dimilier K, 202 и 2013) [243].

Электромагнитная томография (ЭМТ) - это технология визуализации, которая привлекает интерес тем, что она неинвазивна, безопасна, а также отличается высокой практичностью, низкой стоимостью и бесшумностью, и технология ЭМТ подходит для пациентов с клаустрофобией. [244] и [245] разработали исследования, демонстрирующие, что обнаружение и классификация инсульта могут быть эффективными. возможно использование технологии ЕМТ. Авторы сравнили результаты реконструкции изображения с помощью сенсорного сканера мозга ЕМТ (BRIM G2) с результатами, полученными с использованием вычислительной модели, чтобы продемонстрировать, что технология способна обнаруживать и дифференцировать тип инсульта. Эксперименты на фантомных моделях головы человека показали, что можно увидеть неоднородности с относительно низкой контрастностью ( $\approx -10\%$ ), что доказывает возможность использования ЕМТ для обнаружения, классификации и мониторинга инсультов. Несмотря на его более сложную структуру, общая разница в контрастности, ожидаемая для человеческой головы, меньше, чем для используемого фантома человеческой головы. Однако существует также очевидная необходимость в улучшении общего качества изображения за счет аппаратных и программных усовершенствований текущей конфигурации. Другим недостатком является относительно низкое пространственное разрешение, которое связано с

используемым частотным спектром. В частности, для визуализации головного мозга обычный диапазон частот от 0,5 до 2,0 ГГц ограничен из-за высокого ослабления мозговой ткани. В работе [97] авторы исследовали жизнеспособность ЕМТ при непрерывном мониторинге инсульта, однако обнаружение и идентификация были большой проблемой, поскольку получение изображений в итеративной форме требует решения обратной задачи, требующей больших вычислительных мощностей. Целью исследования было решение обратной задачи, связанной с прототипом, разработанным компанией EMTensor GmbH (Вена, Австрия), с использованием современного моделирования и большого количества параллельных высокопроизводительных вычислений. Для проверки жизнеспособности были использованы синтетические данные, соответствующие численной модели головы человека, перенесшего инсульт, которая со временем увеличивается от небольшого геморрагического инсульта до крупного кровоизлияния. В этом случае предполагается, что относительная комплексная диэлектрическая проницаемость неоднородна. Поскольку система будет использоваться для выявления ишемических или геморрагических инсультов и мониторинга лечения, время восстановления должно быть быстрым. Поэтому они использовали методы конечных элементов высокого порядка, параллельные предварительные проводники с декомпозицией предметной области и метод FreeFem++ solver с открытым исходным кодом на языке предметной области. Восстановленные изображения для каждого тестового примера были получены с общим временем вычислений менее 2 минут (94 секунды для случая с длинным путем) с использованием 4096 ядер Cuda. Авторы приходят к выводу, что ЕМТ - это метод визуализации, который может представлять собой САПР-систему и эффективно дополнять технологии КТ и МРТ. И поскольку это неинвазивное портативное устройство, оно будет иметь очевидное клиническое применение у постели пациента в неврологическом отделении интенсивной терапии (ОИТ).

Краткое изложение результатов сравнения статей подраздела III-с приведено в таблице 2.2.

Таблица 2.2: Список публикаций по классификации типов и подтипов инсульта. столбец st указывает на тип инсульта, (i) ишемический и (h) геморрагический. te указывает на тип обследования. d указывает, является ли база данных общедоступной (pu) или частной (pv). m указывает на показатели оценки. tec указывает на используемую технологию. а auto указывает на уровень автоматизации: (a) автоматический, (s) полуавтоматический или (m) ручной.

Исследователь	Тип инсульта	Тип исследования	База данных	Показатели оценки	Технология	Авто
(Babu et al., 2019) [211]	и	КТ, МРТ	Pu	оценка ретроспективной регистрации изображений (RIRE)	Марковское случайное поле (MRF), СЛ	A
(Reboucas et al., 2017) [212]	инфаркт	КТ	Pu	Экстрактор ABTD	MLP, SVM, kNN, OPF, Bayesian	A
(Reboucas et	инфаркт	КТ	Pu	Время, F-оценка	AHTD	A

al., 2017) [213]						
(Jeena et al., 2015) [214]	и, г	КТ	Pr	ACC, SPC, TRP	SVM (линейный, квадратичный и RBF)	A
(Ostrek et al., 2016) [215]	инфузия	КТ	Pr	ACC, SPC, TRP	Логитбуст	A
(Acharya et al., 2012) [220]	инфузия	КП	Pu	DWT	комбинация дискретного вейвлет-преобразования, SVM	A
(Saba et al., 2016) [223]	инфузия	Ультразвук в режиме В	Pr	AtheroCloud™	cIMT	A
(Cuadrado-Godia et al., 2018) [224]	инфузия	биомаркеры, ультразвуковое исследование	Pr	Измерение LD с использованием DL парадигма, класса AtheroEdge™	cIMT	A
(Huibers et al., 2016) [225]	и	ACST-1	Pr	Кривые выживаемости Каплана-Майера	Бляшки на сонных артериях	A
(Donahue et al., 2019) [230]	инфузия	MPT	Pr	DWI, CTP	DEFUSE-3	A
(Giese et al., 2017) [231]	и	MPT	Pr	DWIv	Сеть генетиков инсульта (SiGN)	A
(Jamthikar et al., 2019) [232]	инфузия	MPT	Pr	CVD	SVM, RF, ANN, CCVRFs	A
(Juttukonda et al., 2019) [233]	и	MPT	Pr	OEF	Транскраниальный ультразвуковой допплер	A
(Acharya et al., 2012) [234]	инфузия	КП	Pr	ROC, AUC	Классификаторы AdaBoost, классификатор SVM	A
(Acharya et al., 2013) [235]	инфузия	КП	Pr	SACI	SVM, RBF	A
(Kuang et al., 2019) [237]	и, г	Бесконтрастное КТ	Pr	DSC, MAD, GC	Архитектура D-UNET, мультирегиональная эволюция неявных во времени контуров (semi-d-unet)	A
(Subudhi et al., 2018) [241]	и	MPT	Pr	Se, Sp, Acc, DSI, JI	DT-FODPSO, OCSP, SVM, RF	A
(Hopfer et al., 2017) [244]	инфузия	Электромагнитная томография	-	Визуальный анализ	Электромагнитный тензор, сканер мозга	A
(Semenov et al., 201) [245]	инфузия	Электромагнитная томография	-	Визуальный анализ	Электромагнитный тензор, сканер мозга	A

## 2.5 Сегментация инсульта

Сегментация изображения – это процесс разделения цифрового изображения на несколько сегментов. Кардозо и др. (2015) предоставляют воспроизводимый прототип для синтеза изображений и производят точную сегментацию аномалий при постобработке мягкой сетевой сегментации. Эрихов и др. (2015) предложили еще один неконтролируемый метод, основанный на значимости, который исследует асимметрию мозга в патологических случаях.

Анализ степени инсульта при каждом обследовании на вшивость важен для определения диагноза и лечения каждого пациента. Реальной моделью для

этого процесса является сегментация вручную, что делает процесс трудоемким и подверженным человеческим ошибкам. Методы автоматической сегментации штрихов очерчивают поврежденную область без вмешательства человека.

[179] проанализировали полуавтоматический процесс сегментации алгоритма кластеризации [180] при проведении компьютерной томографии и МРТ пациентов с ишемическим инсультом. Результаты были сопоставлены с ручной сегментацией, выполненной специалистом, в отношении окончательной карты поражения, времени обработки и межсерверной надежности. База данных, использованная в teste, состояла из 44 изображений (13 КТ, 16 МРТ-DWI и 15 МРТ-T2FLAIR) из Тюбингенского неврологического центра, Германия. Этот алгоритм был интегрирован в инструменты статистического параметрического отображения и использован в SPM8 в MatlabR2013b. Значения DSC ( $\leq 0,87$ ) и коэффициента Джаккарда (JAC) ( $\leq 0,77$ ) показывают, что соответствие между картами повреждений было превосходным, что позволяет предположить, что точность кластеризации сопоставима с основной истиной. Полуавтоматический подход по-прежнему позволяет использовать стратегию контроля качества человеком, которая не реализована в полностью автоматизированных методах, что позволяет избежать увековечения ошибок при последующем анализе.

[181] представляют новый автоматический метод выявления острых поражений при ишемическом инсульте с помощью магнитно-резонансной томографии (МРТ) с использованием текстурных и неконтролируемых изучаемых признаков. Предлагаемый метод умело использует трехмерные контекстуальные данные с использованием подхода, основанного на патчах, который случайным образом извлекает патчи из видимых объемов МРТ. Извлечение текстурных объектов (TFE) с использованием матрицы совпадений уровня серого (GLCM) и неконтролируемое обучение объектов (UFL), основанное на подходах кластеризации k-средних, используются независимо для извлечения объектов из входных патчей. Эти признаки, полученные с помощью двух экстракторов признаков, затем вводятся в классификатор случайного леса (RF), чтобы различать классы нормальных и пораженных объектов. В этой статье предлагается гибридный подход, основанный на сочетании TFE с использованием GLCM и UFL на основе кластеризации k-средних. Гибридный комбинированный подход приводит к более отличительному набору признаков по сравнению с традиционными подходами. Предлагаемый метод был оценен на основе данных обучающего набора 2015 года для очаговой сегментации ишемического инсульта (ISLES). Предложенный метод позволил достичь общего кубического коэффициента (DC), равного 0,886, точности 0,979, отклика 0,831 и точности 0,8201. Количественные показатели показывают, что предлагаемый подход на 28,4%, 27,14% и 5,19% выше существующих методов с точки зрения постоянного тока, точности и обратной связи соответственно. [182] разработал САПР-систему для автоматической сегментации штрихов на КТ-изображениях. Система состоит из радиальной функциональной нейронной сети (RBFNN) и использует

многоцелевой генетический алгоритм (MOGA) для определения структуры классификатора и его входных параметров, минимизируя количество ложных срабатываний, максимизируя точность при одновременном обеспечении обобщения и снижении сложности модели. Оглядываясь назад, [183] и [184] ввели информацию об асимметрии мозга с еще 51 статистической характеристикой, такой как ввод RBFNN, что повысило эффективность метода. Эти авторы использовали свою собственную базу данных для проведения валидационных экспериментов. База состоит из 7 компьютерных томографов головного мозга, разделенных на 150 срезов, полученных с использованием того же оборудования. После использования MOGA были выбраны две модели, эксперимент 1 и 2, и сети были обучены и применены к базе данных. Наилучшие результаты были получены в эксперименте 2 со специфичностью (SPC) 98,01% (т.е. 1,99% ложноположительных результатов) и чувствительностью (TPR) 98,22% (т.е. 1,78% ложноотрицательных результатов) по сравнению с основной истиной, отмеченной нейрорадиологом. Этот подход также сравнивался с другими 3 публикациями, превосходя их по специфичности, точности и прецизионности. Хотя классификатор обладает способностью обнаруживать большинство повреждений, иногда он выявляет ложные повреждения, и это основная проблема, которую необходимо преодолеть. Кроме того, классификатор ограничен одним типом поражения.

Успешное определение контуров поражений при острых ишемических инсултах (ОИИ) имеет решающее значение для повышения вероятности хорошего клинического исхода для пациента. [185] разработали полностью автоматизированный метод локализации и сегментации поражений ИИС в различных локализациях для 192 мультимодальных изображений 3D магнитно-резонансной томографии (МРТ), включая 106 инсультов и 86 здоровых пациентов. Метод работает на основе Т-критерия Кроуфорда-Хаузла и сравнения изображений инсульта со здоровыми контрольными группами. Затем мы разработали классификатор для разделения изображений на категории инсульта или неинсультных после сегментации поражения. Экспериментальные результаты по классификации инсультов от неинсультов показали среднюю точность, безошибочность, чувствительность и специфичность в 73%, 0,77%, 84% и 69% соответственно.

На качество компьютерных изображений может повлиять неравномерность интенсивности рентгеновского излучения во время обследования, что вызывает трудности при выявлении кровоизлияний в мозг. Поэтому в [188] был проведен сравнительный анализ пороговых значений, регионального роста, методов нечеткой кластеризации и активного контурирования в процессе сегментации штрихов. Результаты этих методов сравниваются с основной истиной, изложенной вручную специалистом. Используемая база данных состояла из 10 изображений компьютерной томографии, полученных с помощью томографа (GE Medical Systems), сконфигурированного с полем зрения 25x25 см, пиковым напряжением 120 кВ, током трубки 100 мА и размерами 512x512x3 мм и расстоянием между срезами

10 мм. Для сравнительного анализа были рассчитаны точность, чувствительность, специфичность и перекрытие. Результаты показали, что метод активного контура превосходит по точности другие подходы. Все вышеперечисленные методы полностью или частично ручные, и их эффективность зависит от опыта человека. Таким образом, разработка методов автоматической сегментации для обнаружения инсульта имеет большое будущее.

[189] предложили новый метод сегментации 3D геморрагического инсульта при компьютерной томографии головного мозга. Сегментация выполняется с использованием супервоксельного алгоритма, основанного на простой линейной итеративной кластеризации (SLIC) и уточненного с использованием графового алгоритма. Метод выполняет этап предварительной обработки, применяя алгоритм нечеткого C-среднего (FCM) для удаления черепа и адаптивный порог Otsu для сегментации геморрагической области. Затем местоположение геморрагической области точно определяется путем реконструкции серии 2D-изображений в 3D-пространствах с использованием методов рендеринга. Эксперименты проводились с базой данных из 20 обследований (250-350 КТ 2D изображений) пациентов с внутричерепным кровоизлиянием из отделения нейрохирургии больницы CPLA № 98, Хучжоу, Китай. Изображения были получены с помощью сканера General Electric (GE) в формате Digital Imaging and Communications in Medicine (DICOM) размером 512x512 и пространственным разрешением 0,488x0,468 мм. Результаты были сравнены с truth ground и пятью другими методами 2D-сегментации: method, model, resume, snake model, cut graphics для 2D-изображений, slice + cut graphics для 2D-изображений и алгоритмом superpixel slice. Полученные результаты подчеркивают важность сечений графика SLIC+ для 2D-изображений и предлагаемого метода. Предложенный метод позволил получить истинно положительную долю (TPF) в 97,94%, ложноположительную долю (TF) в 92,26% и второе по величине время выполнения. Экспериментальные результаты показали, что предложенный подход обеспечивает сегментацию, аналогичную разметке вручную и превосходящую существующие 2D-методы по точности и времени. Вкладом этой работы было построение графика энергетической функции срезов для решения конкретной задачи сегментации супервокселей в 3D.

[190] разработали метод автоматизированного подхода к выявлению и количественной оценке сердечного приступа с использованием компьютерной томографии с неконтрастным усилением у пациентов с ИИ.

В этой статье получены TNon-контрастные КТ-изображения пациентов с AIS (6 часов от появления симптомов до КТ), которые также прошли диффузионно-взвешенную (DW) МРТ в течение 1 часа после AIS с мая 2004 по июль 2009 года и были включены в это ретроспективное исследование. В качестве эталонного стандарта использовались ишемические поражения, которые были вручную очерчены на МРТ-изображениях DW. Для выявления сердечного приступа был разработан подход автоматической сегментации,

включающий машинное обучение (ml). Для обучения и валидации модели ml были использованы случайно отобранные несимметричные КТ-изображения 157 пациентов со следами поражения, нанесенными вручную на DW-MРТ-сканировании; остальные 100 пациентов, независимо от производной когорты, были использованы для тестирования. Алгоритм ML был количественно оценен по сравнению с эталонным стандартом (DW-MRI) с использованием графиков Бланда-Альтмана и корреляций Пирсона. Подробный технологический конвейер показан на рис. 9.

Для каждого voxelя на сглаженном изображении были вычислены пять атрибутов для случайного обучения и тестирования в лесу. Во-первых, это были средние единицы Хаунсфилда в окрестностях, сосредоточенные на каждом voxelе в трех различных масштабах, таких как 3 x 3 x 3, 7 x 7 x 7 и 11 x 11 x 11 voxelей. Во-вторых, это была двусторонняя разница в плотности между симметричными областями мозга в разных масштабах. Зеркальное изображение было сформировано путем искажения регистрации горизонтально перевернутого мозга по отношению к исходному мозгу в сглаженном изображении. Разница в voxelах в единицах Хаунсфилда была рассчитана путем вычитания исходного мозга из зеркального мозга. Разница в единицах Хаунсфилда для каждого voxelя была рассчитана в трех различных масштабах, таких как 3 x 3 x 3, 7 x 7 x 7 и 11 x 11 x 11 voxelей. В-третьих, было выполнено измерение гипоаттенуации. Сглаженное изображение было введено в предварительно обученную модель сверточной нейронной сети для формирования карты вероятностей, связанной со степенью гипоаттенуации на неконтрастных КТ-изображениях. Модель сверточной нейронной сети представляла собой архитектуру U-Net и первоначально была обучена с использованием модуля увеличения данных с использованием 100 последующих изображений компьютерной томографии с неконтрастным увеличением из другого исследования с отмеченными вручную ишемическими поражениями. Полученная модель U-Net была дополнительна обучена с использованием 157 четких неконтрастных изображений компьютерной томографии. Итоговая карта вероятности, сгенерированная U-network, служила дополнительным признаком, измеряющим степень гипоаттенуации для каждого voxelя. В-четвертых, это была функция расстояния. Оцененная карта вероятности U-Net представляла собой пороговое значение 0,8 для получения бинарной маски спинномозговой жидкости. Затем к этой бинарной маске было применено евклидово преобразование расстояния, чтобы получить карту расстояний в качестве меры расстояния между voxelом и маской, чтобы потенциально уменьшить эффект частичного объемного эффекта спинномозговой жидкости. В-пятых, это была функция определения местоположения поражения, закодированного в атласе. Вероятностная карта локализации поражения была получена с использованием 100 последующих неконтрастных КТ-изображений из другого исследования, нелинейно записанных на сглаженном изображении и приводящих к признакам локализации поражения.

Эти пять функций были использованы для обучения классификатора случайного леса, руководствуясь эталонным стандартом (ручная сегментация в DW MRI). На этапе тестирования тот же конвейер использовался на 100 изображениях пациентов invisible для получения сегментации поражения. Случайная лесная сегментация поражений была окончательно уточнена путем удаления небольших изолированных островков с использованием анализа связанных компонентов и морфологических операций. Разработанный алгоритм позволяет обнаруживать сердечный приступ на воксельной основе.

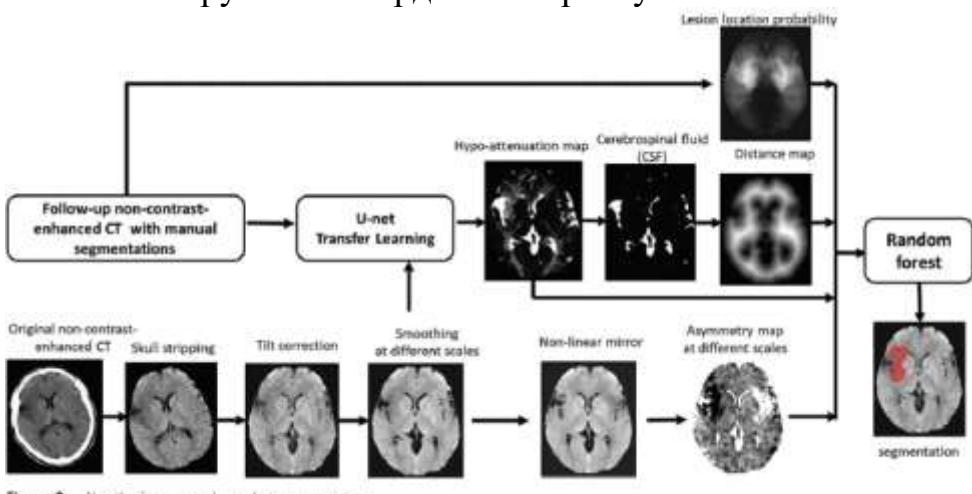


Рисунок 2.11 Алгоритм сегментации острого поражения

[191] разработали новый набор уровневых подходов для сегментации геморрагического инсульта на КТ-изображениях, основанный на вероятности нормального распределения. Метод, называемый Level Set, основанный на анализе плотности рентгеновского излучения головного мозга (LSBRD), добавляет в качестве входных данных анализ интервалов интенсивности пикселей на изображениях в оттенках серого. Авторы приняли 80 HU за ширину окна и 40 HU за центральный уровень и предложили оптимальную инициализацию набора уровней, где нулевой уровень определяется путем анализа рентгенологических плотностей ткани головного мозга. Эти корректировки уровня делают сегментацию линий более эффективной. Предложенный метод был сравнен с алгоритмом установки уровня, основанным на методе когерентного распространения (LSCPM), увеличивающим водораздел и регион. Они были применены к базе данных из 100 обследований, полученных с помощью высокоскоростного компьютерного томографа GE Medical System в кардиологической больнице Форталезы, Бразилия. Результаты были сопоставлены с данными ground truth, сегментированными вручную медицинским специалистом. Предложенный метод был относительно более стабильным и давал средний показатель ACC 99,83% и оценку F выше 92%. Тесты проводились на процессоре Intel Core i5 с частотой 2,4 ГГц и 8 ГБ оперативной памяти с использованием MATLAB. Что касается времени сегментации (в секундах), то метод LSDRD рассчитан на  $1,76 \pm 0,29$  с, в то время как другие методы имеют время сегментации, превышающее 3 секунды. Температура LSCPM составляет  $4,81 \pm 1,18^\circ\text{C}$ . Эти

данные указывают на то, что метод LSDRD превосходит другие методы и, следовательно, является многообещающим методом, который можно использовать в рутинной клинической диагностике, он также имеет хорошее время выполнения и является конкурентоспособным методом для оборудования, используемого сегодня в клинической практике.

Первые признаки ишемии головного мозга трудно заметить и визуально идентифицировать на КТ-изображениях. Чтобы преодолеть это бедствие [192], был предложен метод обнаружения, основанный на увеличении контрастности изображений. Подход решает эту проблему путем улучшения контрастности в нескольких масштабах на основе пирамиды Лапласа (LP) и классификатора нечетких С-средних для выделения ишемизированных областей из нормальной ткани. Для оценки метода результаты предложенного метода были сопоставлены с результатами дискретного вейвлет-преобразования (DWT). Предложенный метод дал наилучшие результаты, кроме того, он показал среднее время обработки 10,46 °С. Целью исследования было улучшить дифференциацию области патологии головного мозга (гиподеномы) от прилегающей нормальной паренхимы. Зона ишемии удаляется вскоре после появления первых признаков ишемического инсульта, чтобы помочь специалистам диагностировать и определить оптимальное лечение. Однако результаты экспериментов показали, что предложенный метод лучше подходит для небольших ишемических инсультов. В случае больших или множественных поражений обоих полушарий алгоритм не дает удовлетворительных результатов, поскольку размер улучшенных частей зависит от количества уровней декомпозиции. Если количество уровней декомпозиции увеличивается, то это влияет на внешний вид изображения.

Алгоритмы сегментации ишемического инсульта при МРТ-сканировании постоянно исследовались, но полученные результаты до сих пор не позволяют провести сравнительный анализ из-за использования различных баз данных и схем валидации. Среди проанализированных работ эта проблема была рассмотрена в статье [193], посвященной проблеме сегментации ишемического инсульта (ISLES), организованной совместно с конференцией Medical Image Computing and Computer Assisted Intervention (MICCAI'15). В случае островков предусмотрена структура оценки для сравнения алгоритмов. Подробно описан набор общедоступных данных, а также результаты двух подзадач: сегментации подострого инсульта (SISS) и оценки перфузии при наводнении (SPES). SISS состояла из базы данных о 64 случаях ишемического инсульта во время МРТ-сканирования, разделенных на T1, T2, T2FLAIR и DWI. Эти снимки были предоставлены медицинским центром Университета Шлезвиг-Гольштейн в Любеке и отделением нейрорадиологии клиники rechts der Isar в Мюнхене, Германия. Оба центра оснащены системами Phillips 3T. База данных SPES содержала результаты магнитно-резонансной томографии пациентов с ишемическим инсультом, которые проходили лечение в университетской больнице Берна, Швейцария, с 2005 по 2013 год. МРТ-снимки были сделаны на системе 1,5 Т (Siemens Magnet Avanto) или 3T MRI (trio Siemens Magnet). Всего

в исследовании приняли участие 16 исследовательских групп с 21 алгоритмом автоматической сегментации. После анализа результатов была проведена критическая оценка текущего состояния технологии, даны рекомендации относительно будущих изменений и выявлены оставшиеся проблемы. Таким образом, ни один алгоритм не работает лучше других, но подходы, использующие комбинации нескольких методов и/или знания предметной области, работают относительно хорошо. Сегментация поражений в SPE была признана жизнеспособной.

В одном исследовании исследователи продемонстрировали высокую точность обнаружения и сегментации поражений с использованием сложных нейронных сетей (CNNS) для извлечения прогностических признаков из диффузионно-взвешенных изображений (DWI) [194]. Болдсен и др. Предложил неконтролируемый мультимодальный алгоритм ATLAS (автоматическое деревовидное обучение). Сегментация аномалий), объединяющий данные DWI и кажущегося коэффициента диффузии (ADC) для идентификации острых ишемических поражений [195]. Показатели Atlas были значительно выше, чем текущий боевой балл [196].

Другие исследования были сосредоточены на использовании прогностической аналитики для интерпретации КТ-изображений. В одном исследовании программа ранней компьютерной томографии Альберты (ASPECTS) использовала классификатор изображений машинного обучения для интерпретации КТ головного мозга и показала не меньшую производительность, чем эксперты по инсульту [197]. Чен и соавт. Валидировали алгоритм m1, который может обнаруживать и количественно оценивать заболевание мелких сосудов головного мозга на КТ-изображениях, а также точно оценивать консенсус экспертов с использованием МРТ-изображений FLAIR [198]. В другом исследовании машинное обучение показало чувствительность 97,5% для обнаружения признаков гиперплотной средней мозговой артерии (MCA) на КТ-изображениях [199].

Многие исследования были сосредоточены на использовании передовых инструментов машинного обучения для автоматической сегментации медицинской визуализации при инсульте. Автоматическая сегментация изображений - одна из горячих точек применения искусственного интеллекта. На конференции ISLES 2015 года "Проблема сегментации при ишемическом инсульте" [200] была представлена первая размещенная модель для трехмерной сверточной нейронной сети [201], которая была впервые предложена при мультимодальной МРТ головного мозга глубиной 11 слоев и полностью автоматизированном методе многомасштабной сегментации. Другие примеры включают Pustin et al. [202], которые реализовали двухслойную сверточную нейронную сеть, используемую при анализе данных идентификации окрестностей, Чен и др. [203], которые использовали двухслойную сверточную нейронную сеть для выполнения автоматической сегментации, мало чем отличающейся от ручной сегментации, Шерер и др. [204], которые использовали модель автоматической сегментации, реализующая метод

случайного леса для точного сегментирования объема гематом при кровоизлиянии в мозг на компьютерной томографии и Prevedello et al. [205], которые разработали алгоритм искусственного интеллекта для обнаружения кровоизлияния в мозг, эффекта массы, гидроцефалии и других признаков при компьютерной томографии с использованием метода dl, который достиг высокой точности. Позже Чен и другие [206] разработали основанный на ml алгоритм, который автоматически сегментировал и количественно определял спинномозговую жидкость при последовательном компьютерном исследовании пациентов, перенесших инсульт, тем самым прогнозируя прогрессирование отека головного мозга. Сочетание искусственного интеллекта и медицинской визуализации обеспечивает более точную интерпретацию результатов визуализации, которая является одновременно быстрой и качественной.

Учитывая высокий уровень заболеваемости и смертности, а также короткий промежуточный период после инсульта, крайне важно, чтобы врачи диагностировали инсульт как можно точнее и принимали оперативные меры при первом посещении. Абеди и др. представили очень хорошую заявку. [207] в виде искусственной нейросетевой модели для анализа медицинских данных, включая клинические проявления, данные анамнеза и визуализации пациентов с симптомами, подобными инсульту, в течение 4,5 часов после появления симптомов, позволяет быстро диагностировать острую ишемию головного мозга и дифференцировать ее от других типов заболеваний, аналогичных погладить. Всего в это исследование было включено 260 пациентов, и было проведено 10 раундов обучения и тестирования моделей искусственных нейронных сетей. Они разработали модель ANN с использованием пакета программного обеспечения Neuralnet R и построили 10 нейронных сетей на основе 10 обучающих наборов. Результаты показали, что чувствительность и специфичность диагностики ишемии головного мозга составили 80,0% и 86,2% соответственно, а медиана точности составила 92%. Хотя эта модель не могла различать передний или задний подтипы ишемии, она продемонстрировала большой потенциал искусственной нейронной сети в облегчении быстрой диагностики ишемического инсульта. Дополнительные исследования по сегментации инсульта обобщены в таблицах 2.3, 2.4.

Таблицы 2.3, 2.4: Список приложений для сегментации штрихов на основе искусственного интеллекта

Исследование	Тип инсульта	Тип исследования	Технология	Уровень автоматизации	Тип базы данных (общедоступная/частная)	Показатели оценки	Исход
(de Haan и др., 2015) [179]	и	CT, MRI( DWI, T2FLAIR)	Clusterize +SPM8	A	Pv	DSC, JAC	CT dataset: average lesion volume $28.24 \text{ cm}^3$ -1 <sup>st</sup> rate, $27.54 \text{ cm}^3$ -2 <sup>nd</sup> rate, ICC -.994 DWI dataset: avl $27.71 \text{ cm}^3$ -1 <sup>st</sup> rate, $19.39 \text{ cm}^3$ -2 <sup>nd</sup> rate, ICC -.962 T2FLAIR dataset: avl 15.59

							$\text{cm}^3$ -1 <sup>st</sup> rate, 17.95 -2 <sup>nd</sup> rate, ICC -.984
(Bharathi и др., 2019) [181]	и	MRI	RF, TFE+GLC M, UFL		Pv	ROC	Dice coefficient of 0.886, precision of 0.979, recall of 0.831, accuracy of 0.8201
(Hajimani и др., 2015) [182]	инсульт	CT	NN+MOGA		Pv	ACC, PPV, SPC Visual and Correlation	the number of False Detections (FD) in both validation and test sets in the model obtained by the proposed work is lower than that of the SVM
(Hajimani и др., 2017) [184]	инсульт	CT	RBFNN+ MOGA	A	Pv	non-dominated models on	Values of specificity of 98% and sensitivity of 98%
(Nazari-Farsani и др., 2020) [185]	и	3DMRI (DWI)	Crawford-Howell t-test, SPM12	A	Pv	192 multimodal MRI	The mean Dice similarity coefficient (DSC) for the test set was $0.50 \pm 0.21$ (min-max: 0.07 to 0.83) and mean net Doverlap was $0.66 \pm 0.18$ (min-max: 0.22 to 1).
(Aghaei и др., 2017) [186]	г	CT-NC	a multilayer region growing algorithm with adaptively adjusted thresholds	A	Pv	from Mod Rotterdam and Helsinki sales	The new CAD tool used in clinical and research settings
(Xue и др., 2019) [187]	инсульт	MRI	a multi-modal multipath convolutional neural network system	A	Pv	nine end-to-end UNets	high Dice values for many smaller lesions
(Sun и др., 2015) [189]	Г	CT	FCM, Otsu's thresholding, SLIC+Graph cuts	A	Pu	TPF, FF	the average TPF of 97.94% and FF 92.26%
(Qiu и др., 2020) [190]	И	CT, MRI	random forest training and testing	A	Pu	Compared with Bland-Altman plots and Pearson correlation	CT (IQR, 27–93 minutes); MRI (IQR, 24–48 minutes)
(Yahiaoui и Bessaid и др., 2016) [192]	И	CT	LP, FCM	A	Pv	Visual	Region Of Interest (ROI), the average processing time is 10.46 s.
(Maier и др., 2017) [193]	и	MRI-DWI, T1, T2, T2FLAIR	Various techniques	A	Pu	DSC, HD, ASSD	no algorithmic characteristic of any method was found to perform superior to the others
(Chen и др., 2017)	и	MRI-DWI	EDD Net, Muscle	A	Pv	DSC	Lesion detection rate achieved is 0.94

[194]			Net				
(Boldsen и др., 2018) [195]	И	MRI	ATLAS, decision Tree, RAPID COMBAT, thresholds-based	A	Pv	Dice coefficient	RAPID less reproducible, the COMBAT does almost as well as ATLAS
(Nagel и др., 2017) [197]	И	CT	Alberta Stroke Program Early Computed Tomography Score	A	Pu	Bland-Altman plots and Matthews correlation coefficients	Both Matthews correlation coefficients for e-ASPECTS were higher (0.36 and 0.34)
(Chen и др., 2018) [198]	и	CT, MR(FLAIR)	RF	A	Pu	Manual Tracing Studies and Ordinal Rating Studies	Total automated processing time averaged 109 seconds (range, 79–140 seconds).
(Takahashi и др., 2014) [199]	и	CT	a rule-based scheme, SVM	A	Pv	MCA dots and false positives	97.5% sensitivity
(Kamnitsas и др., 2017) [201]	и	MRI	a 3D CNN, a fully connected 3D CRF	A	Pu	DSC metric	Top ranking performance between 14 teams
(Pustina и др., 2016) [202]	и	MRI	LI NDA (Lesion Identification with Neighborhood Data Analysis)	A	Pr	comparative lesion-to-symptom mapping (LSM)	Producing consistent predictions with manual segmentations
(Scherer и др., 2016) [204]	Спонтанное внутри мозговое кровоизлияние	CT	Automatic segmentation algorithm	A	Pu	ICH volume	Strong agreement with manual segmentations
(Prevedello и др., 2017) [205]	Кровоизлияние в мозг	CT	CNN	A	Pr	noncontrast-enhanced head CT (NCHCT) examination	90% (45 of 50) sensitivity and 85% (68 of 80) specificity
(Chen и др., 2016) [206]	Острый ишемический инсульт	CT	RF+GAC	A	Pu	CSF shifts	More accurate than manual delineation.
(Abedi и др., 2017) [207]	В течение 4,5 ч после	clinical materials	10-fold cross-validation method	A	Pu	ACI and SM	80.0% sensitivity; 86.2% specificity

появле ния симпто мов, сходны х с инсуль том						
---	--	--	--	--	--	--

### **3. МАТЕРИАЛЫ И МЕТОДЫ ДЛЯ ДИАГНОСТИКИ ИНСУЛЬТА**

#### **3.1 Материалы с открытым исходным кодом для визуализации инсульта**

Машинное обучение развивается с головокружительной скоростью, намного быстрее, чем может обеспечить обычный экспертный анализ. Поскольку их результаты были хорошо известны и включены в исследования других людей, многие из наиболее известных и популярных статей по ОД за последние несколько лет теперь доступны в виде научных публикаций или материалов конференций и семинаров. Конечно, пропуск экспертной оценки имеет свои недостатки, но они частично нивелируются готовностью исследователей делиться данными и программным кодом.

Большинство основных новых концепций и подходов были опубликованы на сервере препринтов arXiv [133], а соответствующий код размещен на веб-сайте GitHub [134]. Часто используемые наборы данных находятся в свободном доступе в различных репозиториях. Это, наряду с многочисленными отличными возможностями онлайн-обучения [135], позволяет легко начать работу в этом секторе. Выберите интересующую вас проблему на основе общедоступных данных, решения, описанного в препринте, и реализации на GitHub. Это отличное место для запуска увлекательного проекта по машинному обучению.

Еще одной интригующей особенностью современного ML и data science является распространение турниров, а ежегодный конкурс ImageNet ILSVRC с 2012 года служит основным стимулом для развития глубокого обучения компьютерному зрению. Каждое соревнование привлекает огромное количество участников, и лучшие результаты часто приводят к новым достижениям. Соревнования не только вдохновляют на инновационные разработки, но и служат естественными отправными точками в передовом машинном обучении. Модели, основанные на глубоком обучении, занимают лидирующие позиции практически во всем контенте, основанном на изображениях, что не может не радовать. Классические методы ML, а также подходы, которые не ориентированы на ML, в основном превзойдены.

То, что в целом актуально для машинного обучения, становится особенно актуальным в области машинного обучения для обработки медицинских изображений. В таблицах 3.1, 3.2 и 3.3 представлены несколько примеров общедоступных реализаций, наборов данных и проблем.

Таблица 3.1 Краткий список общедоступных кодов для ML в визуализации инсульта

Краткое изложение	Ссылка	Реализация	Описание
ReadSNP	[136]	<a href="http://uadi.project.uq.edu.au/UADI/stroke/ReadSNP.zip">http://uadi.project.uq.edu.au/UADI/stroke/ReadSNP.zip</a>	Кодируется на языке Java. Вы можете использовать его для визуализации сигналов рассеяния с параметром S с 16-кратной амплитудой от антенны.
Scikit-rf	[137]	<a href="https://scikit-rf.readthedocs.io/en/latest/tutorials/Introduction.html">https://scikit-rf.readthedocs.io/en/latest/tutorials/Introduction.html</a>	Инженерный пакет для радиочастотной и микроволновой обработки, реализованный на языке программирования Python.
Расширение и	[133]	<a href="https://github.com/apolanco">https://github.com/apolanco</a>	Использование GAN для генерации

сегментация данных с помощью GANs для медицинских изображений		<a href="#"><u>3225/Data-Augmentation-and-Segmentation-with-GANs-for-Medical-Images</u></a>	рандомизированных изображений МРТ головного мозга из случайного шума. Используя условный GAN (pix2pix), вы также можете переводить изображения из одной области в другую: Сегментация анатомии мозга; Создание МРТ головного мозга на основе сегментации; Расширение возможностей перевода изображений в ограниченном наборе данных для выполнения сегментации ишемического инсульта.
Imorrage	[134]	<a href="https://github.com/farisfizal/imorrage">[https://github.com/farisfizal/imorrage]</a>	Анализ изображений компьютерной томографии черепа для выявления и описания кровоизлияний, связанных с инсультом
DeepLearningFor Stroke	[135]	<a href="https://github.com/jbriscoe1/DeepLearningForStroke">[https://github.com/jbriscoe1/DeepLearningForStroke]</a>	Проект глубокого обучения для диагностики ишемического инсульта с использованием бесконтактной компьютерной томографии
Acute-ischemic-lesion-segmentation-in-NCCT	[136]	<a href="https://github.com/WuChanada/Acute-ischemic-lesion-segmentation-in-NCCT">[https://github.com/WuChanada/Acute-ischemic-lesion-segmentation-in-NCCT]</a>	Acute-ischemic-lesion-segmentation-in-NCCT
AHABANDRO--African-Herbal-Medicine-Expert-System	[137]	<a href="http://www.ahabandro.ga">[http://www.ahabandro.ga]</a>	Экспертная система фитотерапии на базе Интернета для диагностики и профилактики инсульта
SUNet	[138]	<a href="https://github.com/NIC-VICOROB/SUNet-architecture">[https://github.com/NIC-VICOROB/SUNet-architecture]</a>	Sunset - это модель глубокого обучения для сегментации острых поражений после инсульта и прогнозирования результатов мультимодальной МРТ.
X-Net	[139]	<a href="https://github.com/Andrews her/X-Net">[https://github.com/Andrews her/X-Net]</a>	X-Net: Сегментация очагов поражения при мозговом инсульте на основе разделяемой по глубине свертки и долгосрочных зависимостей
CLCI_Net	[140]	<a href="https://github.com/YH0517/CLCI_Net">[https://github.com/YH0517/CLCI_Net]</a>	CLCI-Net: Межуровневые сети слияния и контекстного вывода для сегментации очагов хронического инсульта
Ischleseg	[141]	<a href="https://github.com/CarlosU ziel/ischleseg">[https://github.com/CarlosU ziel/ischleseg]</a>	Сегментация очага ишемического инсульта с помощью CNN

Таблица 3.2: Открытые наборы данных и хранилища для визуализации инсульта

Название	Краткое изложение	Ссылка
ХНФИ: Хранилище нейровизуализационных фенотипов инсульта	Хранилище фенотипов нейровизуализации после инсульта (SNIPR) было разработано как крупное многоцентровое централизованное хранилище изображений клинических КТ и МРТ-снимков пациентов, перенесших инсульт, по всему миру на основе расширяемого инструментария архивирования нейровизуализации (ХНФИ). [142-143]	[142] [143]
Набор данных "Анатомические характеристики поражений после инсульта" (АХППИ) - выпуск 1.1, 2017 (ICPSR 36684)	Набор данных "Анатомические признаки поражений после инсульта" (ATLAS), версия 1.1, представляет собой набор данных с открытым исходным кодом, состоящий в общей сложности из 304 МРТ, взвешенных по T1, с сегментированными вручную различными поражениями и метаданными. [144-146]	[144] [145] [146]
Набор данных для "Классификации инсульта в электромагнитной визуализации с использованием графических подходов"	Предложенные сигналы используются для классификации инсультов с использованием электромагнитных сигналов. Шесть реалистичных головных фантомов, созданных на основе изображений МРТ, окружены 16-дипольной антенной решеткой, равномерно распределенной по всей голове. Эти антенны расположены в виде неподвижной круглой решетки вокруг головки с зазором около 2-3 мм между ними и головкой. Каждая из антенн последовательно излучает гауссовский импульс с полосой пропускания от 0:7 до 2 ГГц, в то время как все антенны собирают рассеянные сигналы. В	[147] [148] [149]

	качестве входных сигналов используются сигналы 256 каналов, поскольку было использовано 16 антенн. [147-149]	
OpenNeuro	Лицензированная общественностью открытая платформа для обмена данными нейровизуализации. В эту коллекцию включены снимки мозга, полученные в ходе 168 исследований (4718 человек) с использованием различных методов визуализации и сбора данных. [150]	[150] <a href="https://openneuro.org">https://openneuro.org</a> <sup>a</sup>
Набор данных UCLH Stroke EIT	В рамках клинического исследования были получены данные о многочастотной ЭИТ (FEIT) у 23 пациентов, перенесших инсульт, и 10 здоровых добровольцев. При 31 текущей инъекции данные были получены на 17 частотах в диапазоне от 5 Гц до 2 кГц, что позволило получить 930 образцов на каждой частоте. Это наиболее полный набор данных в своем роде, позволяющий проводить комплексный анализ данных MFEIT, электроэнцефалографии (ЭЭГ) и КТ или МРТ у пациентов, перенесших инсульт, что может послужить основой для будущих исследований по классификации инсультов. [151-152]	[151] <a href="https://github.com/EIT-team/Stroke_EIT_Dataset">https://github.com/EIT-team/Stroke_EIT_Dataset</a> [152]
UK Biobank	Электронные данные о состоянии здоровья полумиллиона человек. Включены МРТ-снимки 15 000 человек, с целью охвата 100 000 человек. [153]	[153] <a href="http://www.ukbiobank.ac.uk/">http://www.ukbiobank.ac.uk/</a>
Набор данных для "Количественной визуализации CEST переноса амидных протонов при остром инсульте"	Набор сравнительных данных (6 методов количественной оценки), используемых при количественной визуализации переноса амидных протонов CEST при остром инсульте. [154]	[154] <a href="https://ora.ox.ac.uk/objects/uuid:3b6ba5ea-d607-423aa34f-e17e0c29183d">https://ora.ox.ac.uk/objects/uuid:3b6ba5ea-d607-423aa34f-e17e0c29183d</a> [155]
База данных NHRI (Национальная исследовательская база данных по медицинскому страхованию)	Национальная исследовательская база данных по медицинскому страхованию Тайваня [156-157]	<a href="https://nhird.nhri.org.tw/en">https://nhird.nhri.org.tw/en</a> [156] [157]

Таблица 3.3 Краткий список соревнований по визуализации инсульта

Название	Краткое изложение	Ссылка
Диагностика внутрисернистых кровоизлияний RSNA 2019	Для выявления острого внутрисернистого кровоизлияния и его подтипов [158]	<a href="https://www.kaggle.com/c/rsna-intracranial-hemorrhage-detection/overview?utm_medium=email&amp;utm_source=intercom&amp;utm_campaign=competition-recaps-rsna-2019">https://www.kaggle.com/c/rsna-intracranial-hemorrhage-detection/overview?utm_medium=email&amp;utm_source=intercom&amp;utm_campaign=competition-recaps-rsna-2019</a>
Задача по гармонизации многооболочечной диффузионной МРТ 2018	Цель исследования - оценить вычислительную эффективность, позволяющую согласовать данные магнитно-резонансной томографии с несколькими оболочками [159].	<a href="https://projects.iq.harvard.edu/cdmri2018/challenge">https://projects.iq.harvard.edu/cdmri2018/challenge</a>
MRBrainS18	Цель этого исследования - оценить методы сегментации серого вещества, белого вещества, спинномозговой жидкости и других областей головного мозга с помощью 3Т-МРТ-изображений, а также оценить влияние (серезных) заболеваний на сегментацию и волюметрию. [160]	<a href="https://mrbrains18.isi.uu.nl/">https://mrbrains18.isi.uu.nl/</a>
iSeg-2017	Используя T1- и T2-взвешенные МРТ-изображения головного мозга, сравните (полуавтоматические) методы сегментации тканей головного мозга 6-месячного ребенка и измерения связанных структур [161].	<a href="http://iseg2017.web.unc.edu/">http://iseg2017.web.unc.edu/</a>
Grand-Challenges	Анализ биомедицинских изображений сопряжен со значительными трудностями. На этом сайте	<a href="https://grand-challenge.org/">https://grand-challenge.org/</a>

	проводится значительное количество конкурсов, список которых опубликован на сайте. [162]	
ISLES 2018	Сегментация очагов ишемического инсульта, 2018. Цель состоит в том, чтобы сегментировать очаги инсульта на основе данных острой компьютерной перфузии [163].	<a href="http://www.isles-challenge.org/">http://www.isles-challenge.org/</a>
Проблема сегментации WMH	Цель этой работы - сравнить методы автоматической сегментации гиперинтенсивности белого вещества, которые, как считается, имеют сосудистое происхождение [164].	<a href="https://wmh.isi.uu.nl/">https://wmh.isi.uu.nl/</a>

### 3.2 Применение Интернета медицинских технологий для диагностики инсульта

Своевременная диагностика и лечение инсульта значительно различаются в разных странах и даже в пределах одной страны. Развивающиеся страны сталкиваются с более серьезными проблемами из-за ограниченного доступа к ресурсам и информации. Ранняя диагностика при подозрении на инсульт может значительно снизить частоту возникновения инсульта, поскольку время является решающим фактором в развитии инсульта. В последние годы был достигнут значительный прогресс в лечении инсульта, включая использование тромболитических препаратов для растворения тромбов при ишемическом инсульте и малоинвазивных хирургических методов лечения геморрагического инсульта. Однако доступ к этим методам лечения во многих частях мира ограничен. Решение проблемы инсульта требует глобальных усилий, включая инвестиции в научные исследования, совершенствование систем здравоохранения, разработку методов ранней диагностики, профилактических и образовательных программ, а также обеспечение равного доступа к качественному лечению и реабилитации для всех людей, независимо от их местоположения и экономического статуса.

Исследование сонных артерий с помощью ультразвукового датчика непрерывного действия (CW) является важным методом диагностики и оценки риска мозгового инсульта. Этот метод позволяет оценить кровоток в сонных артериях, которые являются одними из основных сосудов, снабжающих кровью головной мозг. Нарушение кровотока в этих артериях может привести к ишемическому инсульту. Использование ультразвукового датчика непрерывного действия (CW) для оценки скорости кровотока в сонной артерии позволяет непрерывно регистрировать скорость кровотока по сосудам, но без точного определения глубины, что может ограничить точность измерений локализации. Тем не менее, этот метод позволяет проводить раннюю диагностику и выявлять первые признаки инсульта и может дать представление о наличии или отсутствии патологических изменений в сосудах, таких как стенозы. Непрерывно-волновой ультразвуковой датчик работает на частоте 4 МГц с допуском  $\pm 10\%$ , измеряет скорость кровотока в сонных артериях на основе эффекта Допплера. Эффект Допплера — это изменение частоты волн, воспринимаемых наблюдателем, когда источник этих волн и наблюдатель движутся относительно друг друга. Этот эффект назван в честь австрийского физика Кристиана Допплера, который впервые описал его в 1842 году. Когда

источник волн приближается к наблюдателю, волны «сжимаются», и наблюдатель воспринимает увеличение частоты волн. Если источник удаляется от наблюдателя, волны «растягиваются», и частота, воспринимаемая наблюдателем, уменьшается, рисунок 3.1.

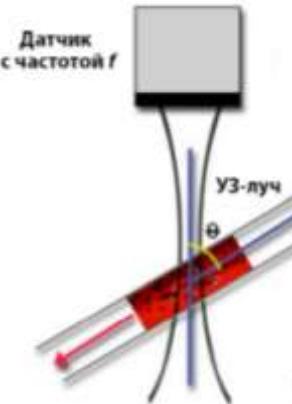


Рисунок 3.1 Принцип допплерографии основан на измерении скорости движения частиц в области распространения луча по изменению Допплеровского фазового сдвига получаемого сигнала.

Скорость кровотока измеряется по формуле

$$V = \frac{f_d \times C}{2 \times f_0 \times \cos \theta} \quad (15)$$

где,  $V$  – скорость кровотока,  $f_d$  – частота Доплера, разность между частотой отраженной волны и исходной частотой волны,  $C$  – скорость звука в ткани, в среднем м/с,  $f_0$  – исходная частота ультразвуковой волны,  $\theta$  – угол между направлением кровотока и направлением ультразвукового излучения [165].  
Во время диагностики с помощью датчика получаем несколько параметров:

- Пиковая систолическая скорость (Peak Systolic Velocity, PSV):  
Максимальная скорость кровотока в систолу сердечного цикла.  
Повышенные значения PSV могут указывать на стеноз сонной артерии.
- Конечно-диастолическая скорость (End-Diastolic Velocity, EDV):  
Скорость кровотока в конце диастолы. Увеличение EDV может также свидетельствовать о наличии стеноза.
- Средняя скорость (Mean Velocity, MV): Среднее значение скорости кровотока за сердечный цикл.
- Индекс сопротивления (Resistance Index, RI) и Индекс пульсации (Pulsatility Index, PI): Эти параметры рассчитываются на основе изменений скоростей кровотока в разные фазы сердечного цикла и могут дать информацию о сопротивлении в сосудистом русле. Они помогают оценить степень эластичности сосудов и наличие препятствий для кровотока.

CW датчик генерирует ультразвуковые волны, частота которых приблизительно составляет 4 МГц. Эта частота выбрана потому, что она обеспечивает оптимальное сочетание глубины проникновения и разрешения для исследования сонных артерий. В непрерывно-волновом режиме датчик

одновременно отправляет ультразвуковые волны и принимает отраженные волны. Отличие CW Doppler от пульсового допплеровского ультразвука в том, что в CW режиме отправка и прием сигналов происходят непрерывно. По принципу эффекта Допплера ультразвуковые волны сталкиваются с движущимися частицами крови в артерии, они отражаются обратно к датчику с измененной частотой в зависимости от скорости движения кровяных частиц. Отраженные волны возвращаются к датчику с измененной частотой. Это изменение (допплеровский сдвиг) прямо пропорционально скорости кровотока. Разница между испущенной и принятой частотами анализируется для определения скорости крови. Данные о допплеровском сдвиге обрабатываются, и результаты визуализированы на экране в виде графиков и цифровых данных. CW Doppler эффективен для обнаружения очень высоких скоростей кровотока, которые встречаются в сонных артериях, особенно при стенозе. Поскольку устройство отправляет и принимает сигналы непрерывно, оно обеспечивает стабильное и непрерывное измерение. Таким образом, непрерывно-волновой допплеровский датчик на частоте 4 МГц является эффективным инструментом для измерения скорости кровотока в сонных артериях, благодаря своей способности непрерывно собирать данные о скорости кровотока без значительной потери детальности сигнала. CW датчик подключен к одноплатному компьютеру Raspberry Pi 4, через аналогово-цифровой преобразователь (АЦП) ADS1115-ADC, который преобразует полученные аналоговые сигналы минус, плюс и GND с CW датчика на цифровые. ADS1115 – это высокоточный, 16-битный АЦП с четырьмя каналами, который подключается через интерфейс I2C. Сигналы датчика подключаются к ADS1115 на входы Ain0 минус сигнал, на VCC плюс сигнал и GND к GND. Подключение к Raspberry Pi осуществляется:

- VCC на ADS1115 подключение к 3.3V на Raspberry Pi.
- GND на ADS1115 подключение к GND на Raspberry Pi.
- SCL на ADS1115 подключение к SCL GPIO 3 на Raspberry Pi.
- SDA на ADS1115 подключение к SDA GPIO 2 на Raspberry Pi.

На Raspberry Pi установлена операционная система Raspbian, а также для работы с ADS1115 установлена на python библиотека adafruit-ads1x15. Чтение данных был написан скрипт на python для считывания данных с АЦП и обработки сигнала. Также были припаяны лампочки зеленого и красного цвета, в случае отсутствия Интернета, подозрение на инсульт выявляется с помощью лампочек, красный – подозрение на инсульт, зеленый – нет подозрений.

Для получения сигнала в графическом виде, также был подключен экран с HDMI входом на Raspberry Pi. Полученные данные скорости кровотока поступают на Raspberry Pi, сравниваются с нормами кровотока, где в таблице 3.4 (Средние линейные скорости кровотока в сонных артериях для разных возрастных групп, см/сек, в норме (по Ю.М. Никитину, 1989)), показаны примеры общепринятых данных по норме. Далее данные отправляются по Интернету в виде отчета о пациенте, с полученными показателями скорости

кровотока к нейрохирургу, для дальнейшего назначения лечения по полученным результатам [165].

Схема подключения CW датчика к Raspberry Pi через АЦП ADS1115 показано на рисунке 3.2.

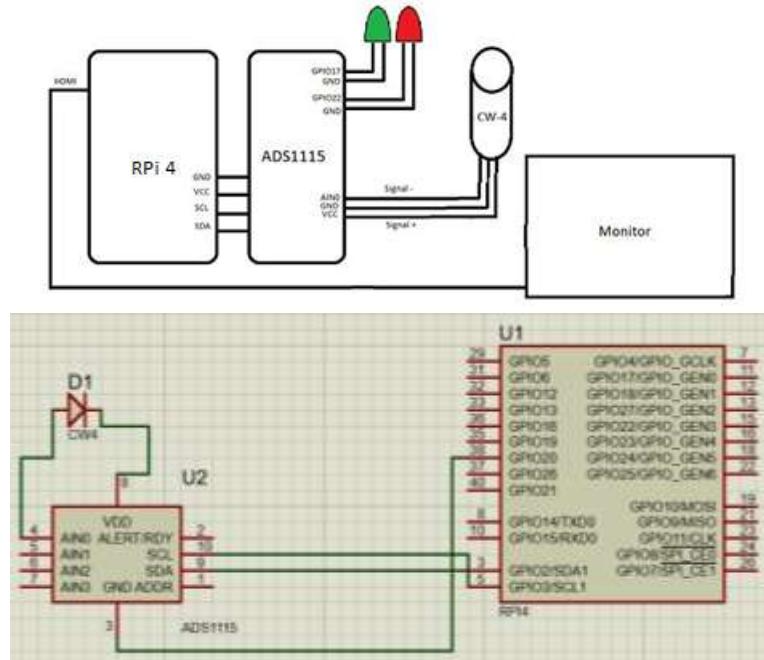


Рисунок 3.2 Функциональная схема подключения датчика CW к Raspberry Pi

На рисунке 3.1 показана функциональная схема работы Интернета медицинских вещей.

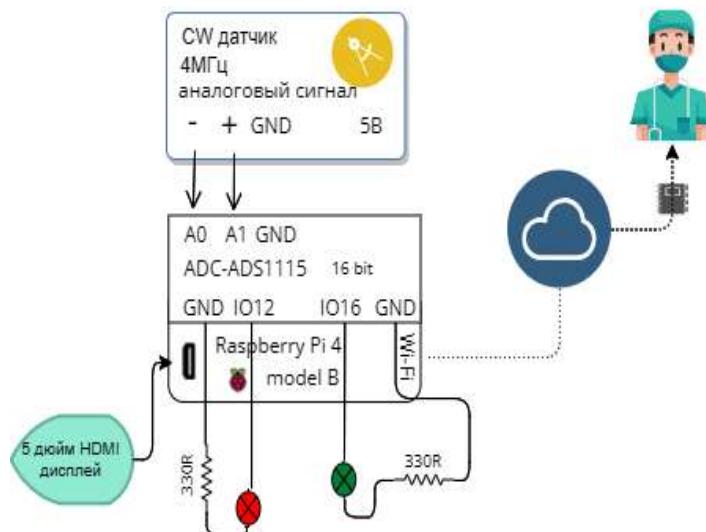


Рисунок 3.1 Функциональная схема IoMT

Изменения скорости кровотока в сонных артериях могут существенно повлиять на здоровье человека, поскольку эти артерии играют ключевую роль в снабжении мозга кислородом и питательными веществами. Изменения могут свидетельствовать о различных заболеваниях, включая атеросклероз или инсульт, и могут привести к различным последствиям для здоровья. Нормальные значения скорости кровотока могут варьироваться в зависимости

от используемых методов, оборудования и индивидуальных особенностей пациента, включая возраст и наличие сопутствующих заболеваний. В целом, для взрослых пациентов нормальные диапазоны скоростей кровотока в сонных артериях могут быть следующими:

**Общая сонная артерия (ОСА):** максимальная систолическая скорость 60-100 см/сек, средняя скорость кровотока 40-60 см/сек.

**Внутренняя сонная артерия (ВСА):** пиковая систолическая скорость может быть немного выше, но если она превышает 125 см/сек, это может указывать на наличие стеноза.

Если ультразвуковое исследование с непрерывной волной обнаруживает значительное увеличение скорости кровотока или другие признаки нарушения кровотока, такие как турбулентность, это может указывать на наличие сужения или других аномалий в сонной артерии, что требует дальнейшего обследования с использованием более точных методов визуализации, таких как цветное допплеровское сканирование, для получения более полной картины. определите точную локализацию и степень поражения сосудов. Показатели кровотока в различных сосудах у здоровых лиц представлены в таблице 3.4 (Средние линейные скорости кровотока в сонных артериях для разных возрастных групп, см/сек, в норме (по Ю.М. Никитину, 1989) на основе исследований Ю.М. Никитина [30]).

Таблица 3.4: Средние линейные скорости кровотока в сонных артериях для разных возрастных групп, см/сек, в норме (по Ю.М. Никитину, 1989)

Артерия	<20 лет	20-29 лет	30-39 лет	40-48 лет	50-59 лет	>60 лет
Левая общая сонная артерия	31,7+1,3	25,6+0,5	25,4+0,7	23,9+0,5	17,7+0,6	18,5+1,1
Правая общая сонная артерия	30,9+1,2	24,1+0,6	23,7+0,6	22,6+0,6	16,7+0,7	18,4+0,8

В таблице 3.5 приведены допплеровские показатели экстракраниальной гемодинамики у пациентов, перенесших ишемический инсульт, с показателями общих сонных артерий [31].

Таблица 3.5: Допплерографические показатели экстракраниальной гемодинамики у пациентов

Обследуемая группа	Артерия	GS, cm/sec
Ишемический инсульт (35 лет)	общая сонная артерия	65,6±4,2*
	внутренняя сонная артерия	51,80±3,98*

### 3.3 Классификация мозговых инсультов с поддержкой глубокого обучения на изображениях компьютерной томографии

Современные приложения искусственного интеллекта предназначены для того, чтобы помогать людям решать самые разные проблемы. CNN - это одна из развивающихся подкатегорий глубокого обучения, которая в настоящее время широко используется в нейровизуализации [12]. Методы глубокого обучения и использование CNN оцениваются как стратегия диагностики острых ишемических инсультов. Популярной темой в области автоматизированной диагностики является сквозная архитектура системы. Недавно в нескольких важных публикациях были представлены реализованные алгоритмы для классификации инсультов головного мозга. Более того, методы сегментации очага ишемического инсульта и прогнозирования риска также применимы для диагностики инсульта [13]. Однако, насколько нам известно, нет методологии или публикации исследования с использованием диффузионно-взвешенной визуализации (DWI) для классификации основных артериальных пространственных типов инсульта [14].

Чтобы решить проблему улучшения диагностики и лечения ишемических церебральных инсультов, в этом исследовании предлагается автоматизированный подход на основе CNN для выявления инфаркта головного мозга при компьютерной томографии. В связи с этим для повышения производительности построенной модели CNN были применены методы предварительной обработки изображений, разработки функциональных возможностей и увеличения объема данных. Наиболее сложным аспектом реализации вышеупомянутых типов приложений является объединение трех факторов, которые редко совместимы: знания в области вычислений, особенно в области анализа изображений, медицинские знания и высокопроизводительные вычисления [15]. Существует ряд исследовательских инициатив в области методов медицинской визуализации, которые используют различные алгоритмы и дают схожие результаты, но ни одна из них не имеет удобного интерфейса для обычных клиницистов [16].

В следующем разделе представлен автоматизированный классификационный подход для определения категории, к которой относится компьютерная томография головного мозга, включая изображения в категориях "геморрагический", "ишемический" и "здоровый". Геморрагический инсульт возникает в результате разрыва закупоренного кровеносного сосуда в головном мозге, который проникает в окружающие ткани. Гипертония, травмы, аномалии кровеносных сосудов, нарушения кровообращения, аневризмы и употребление кокаина являются наиболее распространенными причинами геморрагического инсульта. Ишемический инсульт, с другой стороны, возникает, когда приток крови к мозгу прекращается из-за наличия тромба, или также может привести к опасным для жизни последствиям в виде кровоизлияния в мозг [17]. На рис. 3.2 показаны примеры двух типов инсультов и изображений здорового мозга.

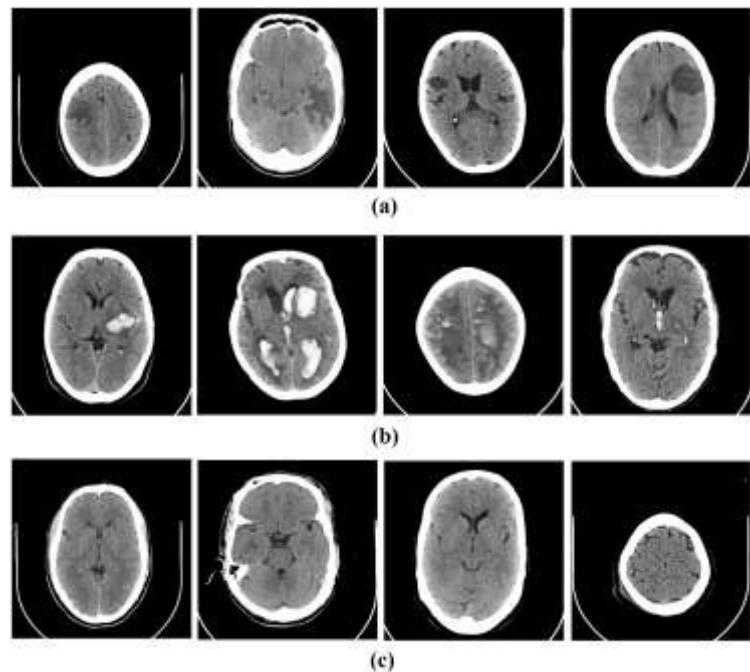


Рисунок 3.2 Образцы КТ-изображений (а) ишемического, (б) геморрагического инсульта и (в) нормального головного мозга

На рис. 3.3 показаны очаги ишемического и геморрагического инсульта, которые были выявлены медицинскими работниками. Области головного мозга, где произошли инсульты, обозначены фиолетовым цветом на рис. 2. 2. Целью нашего исследования является разработка компьютерной диагностической системы на основе модели CNN для автоматизированной классификации мозговых инсультов.

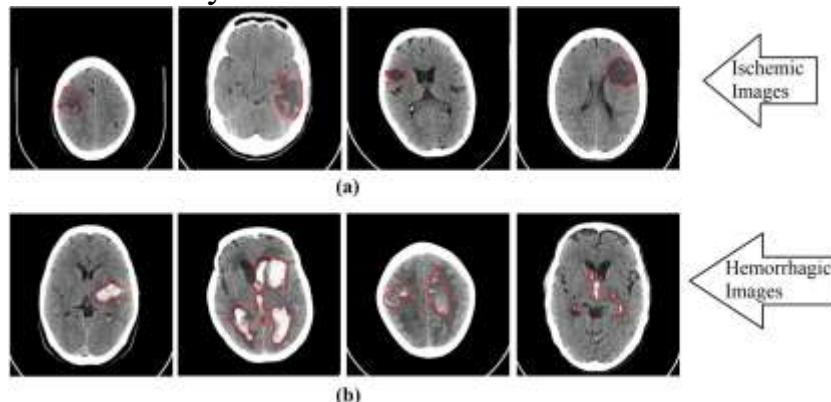


Рисунок 3.3 Красной областью отмечены места ишемических и геморрагических поражений на изображениях

Начальная фаза нашего исследования в классификации посвящена предварительной обработке изображений, которая состоит из таких этапов, как считывание изображения, изменение размера изображения и увеличение данных с использованием метода flip. Инжир. На рис. 3.4 показана структурная схема предлагаемой системы классификации инсультов головного мозга по компьютерным томографическим изображениям. Используя технологии streamlite и ngrok, было создано веб-приложение на python для классификации CNN. Как показано на схеме, пользователь может загрузить изображение мозга в веб-приложение, затем модель CNN классифицирует изображение, а затем

определяет изображение как здоровое или с патологией, вызванной инсультом. Затем полученные результаты можно сравнить с диагнозом медицинского эксперта [167].

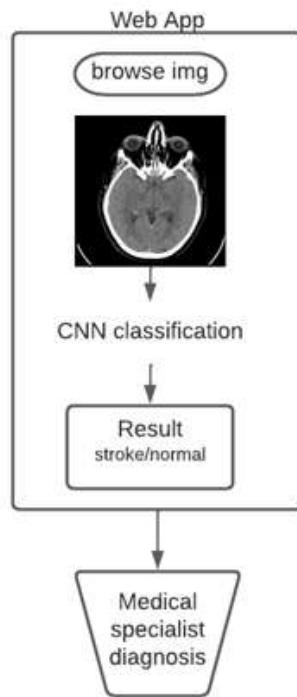


Рисунок 3.4 Блок-схема предлагаемой системы

Входными параметрами изображения для модели CNN были (200, 200, 1). Общее и поддающееся обучению количество параметров составило 214 145. На рис. 3.5 показана архитектура модели CNN для классификации мозговых инсультов. На рис. 6 показан подробный анализ применяемой модели CNN для классификации мозговых инсультов.

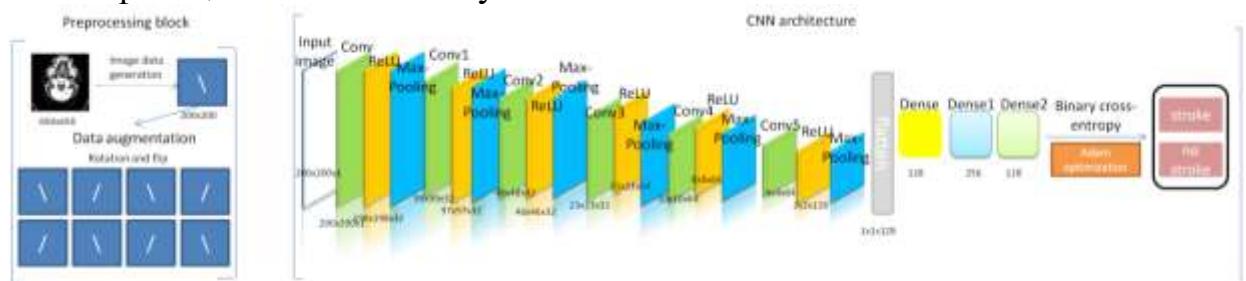


Рисунок 3.5 Архитектура предлагаемого канала CNN

Мы использовали метод увеличения данных с горизонтальной инверсией для получения более точной классификации, которая требует огромного объема данных. Однако, поскольку у нас не было большого количества изображений штрихов, нам пришлось прибегнуть к этому методу.

Использование генератора графических данных позволило нам увеличивать изображения в режиме реального времени и применять любые случайные преобразования к каждому обучающему изображению по мере его ввода в модель. Таким образом, использование этого метода в модели CNN не только обеспечило надежность, но и сэкономило рабочую память.

Решая проблему выбора необходимого количества эпох при обучении нейронной сети, метод ранней остановки позволил остановить обучение, как только модель перестала улучшаться. В результате удалось избежать ситуации переобучения.

Оптимизатор Adam (adaptive moment estimator) был применен для оптимизации модели CNN, а бинарная функция кросс-энтропийных потерь - для расчета потерь, а также показателя точности. Оптимизатор Adam сочетает в себе как идею накопления движения, так и идею более слабого обновления весов для типичных объектов [166].

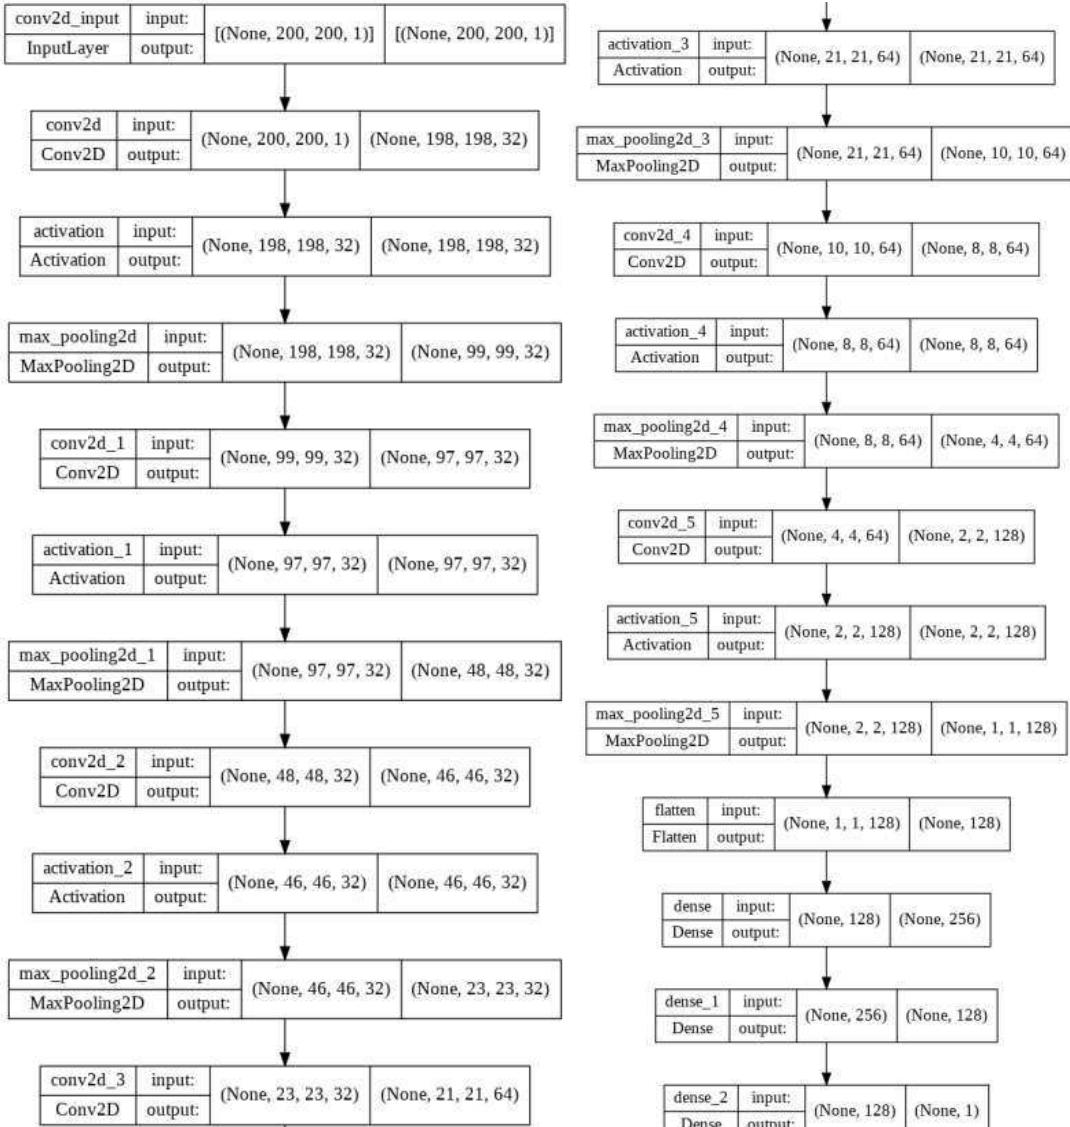


Рисунок 3.6 Предлагаемый канал CNN

### 3.3.1 Наборы данных применяемые для классификация мозговых инсультов с применением глубокого обучения

Цель в данном методе - классифицировать изображения мозга в формате jpg или png, где выделяются два класса: после инсульта или в здоровом состоянии. В качестве набора данных использовалась общедоступная платформа Kaggle [42]. Этот набор данных был разделен на три группы по 80%/20% (тренировочные, валидационные и тестовые) и содержал 993

изображения здоровых людей и 610 случаев инсульта для категории обучения; 240 изображений здоровых людей и 146 случаев инсульта; и 313 изображений здоровых людей и 189 случаев инсульта для тестирования. Изображения в наборе данных были такими, как показано на рис. 3.7

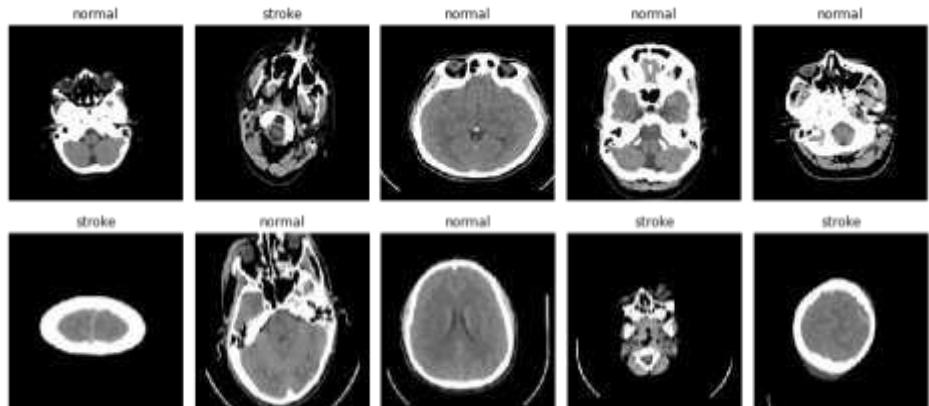


Рисунок 3.7 Содержимое набора данных

### 3.3.2 Методы оценки модели для классификации мозговых инсультов

Аккуратность, точность, отзыв и F1-счет - это показатели, которые мы используем для оценки результатов прогнозирования [43-46]. Точность - это показатель, который иллюстрирует степень точности прогноза модели по всем параметрам. Он измеряется как процент правильных прогнозов, сделанных моделью. Это особенно полезно в ситуациях, когда все классы имеют одинаковую важность. Формула для его определения - это отношение количества точных прогнозов к общему количеству сделанных прогнозов. Фактически, это вероятность того, что класс будет предсказан правильно. Уравнение (16) демонстрирует формулу точности.

$$Accuracy(a) = \frac{\sum_{i=1}^N [a(x_i) = y_i]}{N} = \frac{TP + TN}{TP + TN + FP + FN} \quad (16)$$

Здесь TP - истинно положительные результаты, TN - истинно отрицательные результаты, FP - ложноположительные результаты, FN - ложноотрицательные результаты.

При измерении относительно абсолютной достоверности точность дает точное представление о достоверности наших положительных результатов. Сколько элементов на данной фотографии, которые мы предсказали, соответствовали истинной аннотации? Точность описывается формулой (17) [47].

$$precision = \frac{TP}{TP + FP} \quad (17)$$

Запоминание или чувствительность - это полезный показатель, который можно использовать, пытаясь точно описать, насколько наши оптимистичные прогнозы соответствуют реальному миру. Сколько положительных прогнозов мы получили из всех выражений, приведенных в нашей статье "Основная истина"? [47]

$$recall = \frac{TP}{TP + FN} \quad (18)$$

Среднее гармоническое значение между точностью и полнотой обозначается буквой F-мера. Если точность или полнота стремятся к 0, то и этот показатель равен 0. Уравнение (19) демонстрирует формулу для оценки F-меры.

$$F_{measure} = \frac{2 \text{PrecisionRecall}}{\text{Precision} + \text{Recall}} \quad (19)$$

### 3.3.3 Основные математические формулы

Основные математические формулы для предлагаемой модели классификации на основе CNN.

Входное изображение  $X$  размером (200, 200, 1)

$X = [x_{i,j,k}]$ ,  $i = 1, \dots, 200$  (высота),  $j = 1, \dots, 200$  (ширина),  
 $k = 1$  (канал, изображение черно-белое)

Сверточный слой 1:

$$Y_{i',j',q}^{(1)} = \text{ReLU}(\sum_{m=1}^3 \sum_{n=1}^3 \sum_{p=1}^1 x_{i+m-1,j+n-1,p} \cdot w_{m,n,p,q}^1 + b_q^{(1)}) \quad (20)$$

$W^{(1)} = [w_{m,n,p,q}^{(1)}]$  – фильтры первого слоя, где  $m, n$  – размеры фильтра (3x3),  $p$  – входные каналы (1),  $q$  – количество фильтров.

$b^{(1)} = [b_q^{(1)}]$  – смещение для каждого фильтра.

$i', j'$  – координаты в выходной активационной карте, зависящие от размера фильтра и шага.

Сверточный слой 2:

$$Y_{i',j',q}^{(2)} = \text{ReLU}(\sum_{m=1}^3 \sum_{n=1}^3 \sum_{p=1}^{32} Y_{i+m-1,j+n-1,p}^{(1)} \cdot w_{m,n,p,q}^2 + b_q^{(2)}) \quad (21)$$

$W^{(2)} = [w_{m,n,p,q}^{(2)}]$  – где  $p$  – количество фильтров предыдущего слоя (32),  $q$  – количество фильтров текущего слоя (64).

Сверточный слой 3:

$$Y_{i',j',q}^{(3)} = \text{ReLU}(\sum_{m=1}^3 \sum_{n=1}^3 \sum_{p=1}^{64} Y_{i+m-1,j+n-1,p}^{(2)} \cdot w_{m,n,p,q}^3 + b_q^{(3)}) \quad (22)$$

$W^{(3)} = [w_{m,n,p,q}^{(3)}]$  – где  $p$  – количество фильтров предыдущего слоя (64),  $q$  – количество фильтров текущего слоя (128).

Сверточный слой 4:

$$Y_{i',j',q}^{(4)} = \text{ReLU}(\sum_{m=1}^3 \sum_{n=1}^3 \sum_{p=1}^{128} Y_{i+m-1,j+n-1,p}^{(3)} \cdot w_{m,n,p,q}^4 + b_q^{(4)}) \quad (23)$$

$W^{(4)} = [w_{m,n,p,q}^{(4)}]$  – где  $p$  – количество фильтров предыдущего слоя (128),  $q$  – количество фильтров текущего слоя (256).

Сверточный слой 5:

$$Y_{i',j',q}^{(5)} = \text{ReLU}(\sum_{m=1}^3 \sum_{n=1}^3 \sum_{p=1}^{256} Y_{i+m-1,j+n-1,p}^{(4)} \cdot w_{m,n,p,q}^5 + b_q^{(5)}) \quad (24)$$

$W^{(5)} = [w_{m,n,p,q}^{(5)}]$  – где  $p$  – количество фильтров предыдущего слоя (256),  $q$  – количество фильтров текущего слоя (512).

Пулинг слои (MaxPooling)

$$P_{i',j',q}^{(l)} = \max_{m,n \in [1,2]} (Y_{i+2+m,j+2+n,q}^{(l)}) \quad (25)$$

Уплощение (Flatten)

$$F = Flatten(Y^{(5)}) \quad (26)$$

$Y^{(5)}$  размером  $(h, w, 512)$  преобразуется в вектор размером  $(h \times w \times 512)$

$F = [f_k]$ , где  $k = 1, \dots, (h \times w \times 512)$

Полносвязные слои (Dense)

Полносвязный слой 1:

$$D_j^{(1)} = ReLU(\sum_{i=1}^{h \times w \times 512} f_i \cdot w_{i,j}^{(d1)} + b_j^{(d1)}) \quad (27)$$

$W^{(d1)} = [w_{i,j}^{(d1)}]$  размером  $(h \times w \times 512, 128)$

$b^{(d1)} = [b_j^{(d1)}]$  размером  $(128)$

Dropout:

$$D_{dropout,j}^{(1)} = Dropout(D_j^{(1)}, rate)$$

$rate$  – вероятность зануления нейрона

Полносвязный слой 2:

$$D_k^{(2)} = ReLU(\sum_{j=1}^{128} D_{dropout,j}^{(1)} \cdot w_{j,k}^{(d2)} + b_k^{(d2)}) \quad (28)$$

$W^{(d2)} = [w_{j,k}^{(d2)}]$  размером  $(128, 256)$

$b^{(d2)} = [b_k^{(d2)}]$  размером  $(256)$

Полносвязный слой 3:

$$D_m^{(3)} = ReLU(\sum_{k=1}^{256} D_k^{(2)} \cdot w_{k,m}^{(d3)} + b_m^{(d3)}) \quad (29)$$

$W^{(d3)} = [w_{k,m}^{(d3)}]$  размером  $(256, 128)$

$b^{(d3)} = [b_m^{(d3)}]$  размером  $(128)$

Выходной слой:

$$O = sigmoid(\sum_{m=1}^{128} D_m^{(3)} \cdot w_m^{(out)} + b^{(out)}) \quad (30)$$

$W^{(out)} = [w_m^{(out)}]$  размером  $(128)$

$b^{(out)}$  размером  $(1)$

Бинарный результат:

$$R = \begin{cases} 1 & \text{если } O \geq 0.5 \\ 0 & \text{если } O < 0.5 \end{cases}$$

Функция потерь:

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \cdot \log(O_i) + (1 - y_i) \cdot \log(1 - O_i)] \quad (31)$$

$y_i$  – истинные значения меток.

$O_i$  – предсказанные значения.

$N$  – количество образцов.

Оптимизация (Adam)

Обновление весов:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \nabla L$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) (\nabla L)^2$$

$$\widehat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$\widehat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

$$W = W - \alpha \frac{\widehat{m}_t}{\sqrt{\widehat{v}_t} + \epsilon}$$

где  $\alpha$  – скорость обучения,  $\beta_1$  и  $\beta_2$  – параметры моментов,  $\epsilon$  – малое число для предотвращения деления на ноль.

### **3.4 Модель глубокой нейронной сети на основе UNet для сегментации очагов поражения головного мозга при инсульте на изображениях компьютерной томографии**

В рамках нашей задачи была построена модель глубокой нейронной сети на основе UNet, для достижения более высокой точности сегментации штрихов на КТ-изображениях. Благодаря использованию таких методов, как увеличение объема данных, отсев, алгоритм оптимизации Adam, регуляризация L2 и нормализация экземпляра, мы смогли модифицировать классическую 3D-модель UNet. Преимущества каждого метода описаны ниже:

- Увеличение объема данных. Этот метод позволяет разработчикам искусственно увеличивать размер обучающего набора, создавая данные путем модификации существующего набора данных [36]. Поскольку набор данных ISLES 2018 содержал небольшой объем данных, этот метод использовался для обучения.
- Dropout был разработан для решения проблемы перенастройки нейронной сети во время тестирования из-за большого количества параметров [37].
- Алгоритм оптимизации Adam оптимизирует скорость адаптивного обучения. Он был специально разработан для глубокого обучения нейронных сетей [38].
- Регуляризация L2 решает проблемы мультиколлинеарности (независимые переменные сильно коррелируют) путем ограничения коэффициента и сохранения всех переменных [39].
- Нормализация экземпляра или нормализация контраста предотвращает изменения среднего значения и ковариации для данного экземпляра, тем самым упрощая процесс обучения. Интуитивно понятно, что процесс нормализации позволяет удалить информацию о контрасте данного экземпляра из изображения содержимого в такой задаче, как стилизация изображений, что упрощает генерацию [40].

Схема предлагаемой архитектуры UNet показана на рисунке 3.8 [168]. В данной нейронной сети каждый нейрон связан со всеми нейронами предыдущего слоя, и каждое соединение имеет свой собственный весовой коэффициент. В сверточной нейронной сети при операциях свертки используется матрица малого веса, которая “перемещается” по всему обрабатываемому слою (на входе сети, непосредственно вместе с входным изображением). Слой свертки суммирует результаты поэлементного сложения каждого фрагмента изображения с помощью основной матрицы свертки.

Весовые коэффициенты ядра свертки неизвестны и устанавливаются в процессе обучения [41].

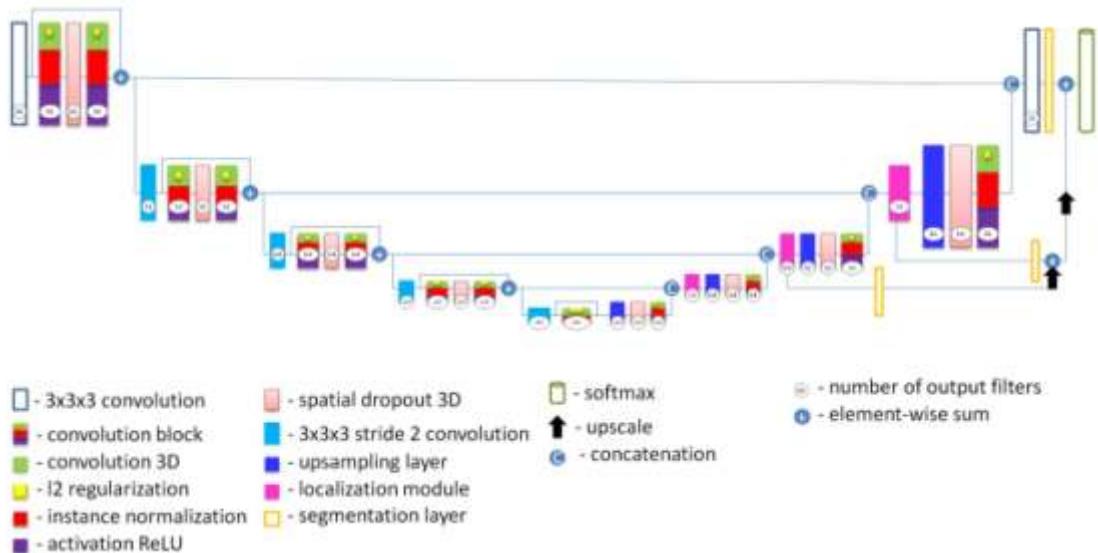


Рисунок 3.8 Предлагаемая измененная архитектура UNet

Оператор свертки вычисляется по формуле:

$$(I * K)_{xy} = \sum_{i=1}^h \sum_{j=1}^w K_{i,j} \times I_{x+i-1, y+j-1} \quad (32)$$

Где  $I$  - двумерное изображение размером  $x \times y$ ;  $K$  - матрица размерности  $h \times w$  (так называемое ядро свертки).

Операция активации является нелинейной функцией и определяет выходной сигнал нейрона, в то время как наиболее часто используемой в современных нейронных сетях и применяемой в этой архитектуре функцией, называемой "выпрямитель" (по аналогии с однопериодическим выпрямителем в электротехнике) [42]. Нейроны с такой функцией активации называются ReLU (выпрямленная линейная единица) и имеют следующую формулу [43]:

$$f(x) = \max(0, x) \quad (33)$$

Эта функция активации значительно ускоряет процесс обучения благодаря простоте вычислений [44-45]. Слой подвыборки уменьшает размер изображения в  $n$  раз по каждой оси, объединяя соседние пиксели в областях размером  $n \times n$  в один пиксель. В качестве значения результирующего пикселя можно использовать среднее значение объединенных пикселей или их максимальное значение. В UNet при выполнении очистки применяется максимизация на площади  $2 \times 2$  пикселя. После прохождения нескольких серий сверточных слоев и слоев подвыборки входное изображение преобразуется из конкретной сетки пикселей с высоким разрешением в более абстрактные карты объектов.

В отличие от других архитектур, в предлагаемой модифицированной UNet некоторые свертки были заменены на расширенные свертки фильтра. Эта модификация расширяет поле зрения фильтра, позволяя модели включать в расчет больше фоновой контекстной информации. Мы используем неплотную активацию ReLU для всех карт объектов, вычисляющих свертки по сети. Чтобы

компенсировать стохастичность, вызванную небольшими размерами пакетов, используемыми из-за нехватки памяти, мы заменяем стандартную пакетную нормализацию на нормализацию экземпляра. Также были добавлены выпадающие слои с регуляризацией 12, чтобы минимизировать переобучение, и в качестве функции потерь мы используем пересечение вместо объединения. В этой архитектуре каждый синий квадрат соответствует карте многоканальных свойств. Количество каналов показано в верхней части квадрата. В левом нижнем углу квадрата показан размер по оси x и y. Белые квадраты представляют собой копии карты свойств. Стрелки указывают на различные операции. Она состоит из сужающегося контура (слева) и расширяющегося контура (справа). Сужающийся путь - это типичная архитектура сверточной нейронной сети. Он заключается в повторном применении двух сверток размером  $3 \times 3 \times 3$ , за которыми следует повторная инициализация и операция максимального объединения ( $2 \times 2$  степени из 2) для уменьшения разрешения. На каждом шаге поникающей дискретизации каналы свойств удваиваются. Каждый шаг в расширяющемся пути состоит из операции увеличения выборки карты свойств, за которой следуют: свертка  $2 \times 2 \times 2$ , которая уменьшает количество каналов свойств; сливание с соответствующим образом обрезанной картой свойств из сокращающегося пути; две свертки  $3 \times 3 \times 3$ , за которыми следует повторное преобразование.. Последний слой использует свертку  $1 \times 1 \times 1$  для сопоставления каждого 64-компонентного вектора свойств с требуемым количеством классов. В общей сложности сеть содержит 23 сверточных слоя. В модели используются следующие размеры данных: форма ввода = [5, 128, 128, 32], уменьшение веса=0. Были рассмотрены две сравнительные архитектуры: классическая 3D-модель UNet за 200 эпох и предложенная 3D-модель UNet за 650 эпох. В результате оценки по основным критериям во время обучения классическая 3D-модель UNet получила результаты по баллам dice/f1 - 48%, точности - 39%, запоминаемости/чувствительности - 99%, индексу Жаккарда - 35%, а предложенная модель во время обучения получила результаты по баллам dice/f1 -90%, точность -83%, отзывчивость/чувствительность -93%, индекс Жаккарда -89% и результат теста классическая 3D-модель UNet получила результаты по показателю dice/f1 -36%, точность -38%, отзывчивость/чувствительность -37%, индекс Джаккарда -32% и из предложенных моделей оценка dice/f1 - 58%, точность - 68%, отзывчивость/чувствительность - 60%, индекс Жаккарда - 66%.

### **3.4.1 Сегментация поражения головного мозга при инсульте с использованием изображений компьютерной томографии на основе глубокой модели U-Net с блоками ResNet**

U-Net считается одной из лучших моделей для сегментации медицинских изображений. В данном разделе мы предлагаем сравнить объединенные модели U-Net с ResNetblock1, ResNetblock2, а также модифицированную модель UNet для сегментации мозгового инсульта на основе изображений компьютерной томографии. Поскольку объем данных для обучения ограничен, в ходе

исследования использовался метод увеличения данных. В основной части, после извлечения объекта, выполняется этап сегментации. Чтобы получить результаты, мы устанавливаем 4 основных критерия оценки, таких как: долговая расписка, оценка dice/F1, отзывчивость или чувствительность и точность. Результаты показывают, что модифицированная модель UNet сегментирует мозговой инсульт с высоким коэффициентом оценки dice/f1 по сравнению с комбинированными блоками UNet+ResNet.

В этом исследовании были использованы методы комбинирования и модификации моделей UNet для улучшения эффективности сегментации инсульта на изображениях компьютерной томографии. В качестве эксперимента мы объединили модель UNet с ResNetblock\_1 и ResNetblock\_2, а также модифицировали саму модель U-Net [169]. В результате объединения в архитектуре UNet+ResNetblock\_1 общее количество параметров составило 4 382 949, из которых обучаемые параметры составляли 4 379 621, а необучаемые параметры - 3 328. В этом эксперименте блок ResNet был добавлен в рамках деконволюции архитектуры UNet. В следующем эксперименте пакетная нормализация UNet+ResNetblock\_2 выполнялась после каждого блока трехмерной свертки, блок ResNet добавлялся к свертке части архитектуры UNet. В этой модели было всего 8 921 641 параметр, из которых 8 921 509 были обучаемыми, и только 132 были неподготовленными. Таким образом, мы поняли, что с каждым разом количество неподготовленных параметров уменьшается. В третьей архитектуре UNet были внесены такие изменения, как нормализация экземпляра и повторная утечка. Количество общих и обучаемых параметров было больше, чем у первых двух – 16 321 121, и, как следствие, количество необучаемых параметров составило – 0. Мы также смогли адаптировать оригинальную 3D-модель UNet, используя такие подходы, как увеличение объема данных, отсев, метод оптимизации Adam, регуляризация 12 и нормализация экземпляра.

Ниже перечислены преимущества каждой стратегии:

- Увеличение объема данных. Разработчики могут использовать эту стратегию для искусственного увеличения размера обучающей выборки путем изменения исходного набора данных [36]. Этот подход был выбран для обучения, поскольку применяемый набор данных включал небольшое количество данных.
- Dropout был создан для решения проблемы необходимости перенастройки нейронной сети во время тестирования из-за большого количества параметров [37].
- Оптимизационный подход Adam повышает эффективность адаптивного обучения. Он был создан с учетом глубокого обучения нейронной сети. [38]
- Ограничивающий коэффициент и сохраняя все переменные, регуляризация L2 устраняет проблемы мультиколлинеарности (независимые переменные тесно связаны) [39].
- Нормализация экземпляра, также известная как нормализация контраста, устраняет изменения в среднем значении и ковариации для одного

экземпляра, упрощая процесс обучения. В стиле job like picture процедура нормализации позволяет исключить информацию о контрасте конкретного экземпляра из изображения содержимого, что упрощает создание [40].

### 3.4.2 Наборы данных применяемые для модели глубокой нейронной сети на основе UNet

В качестве набора данных мы используем ISLES 2018 (Ischemic Stroke Lesion Segmentation Challenge), который состоит из 3D-медицинских КТ-изображений головного мозга [30]. Эта база данных ISLES 2018 доступна по лицензии Open Database, а любые права на отдельные материалы базы данных предоставляются по лицензии Database Content [31]. Данные делятся на три типа: “Обучающие”, “Валидационные” и “Тестовые”. Обучающий набор данных состоит из 63 пациентов. Тестовый набор данных состоит из 40 пациентов. У некоторых пациентов есть две таблицы, чтобы охватить очаг инсульта. Это непересекающиеся или частично перекрывающиеся области головного мозга. Таблицы для каждого пациента обозначены буквами “A” и “B” для первой и второй таблиц соответственно (например, 39\_A = случай 60; 39\_B = случай 61). Формат файла изображения: Формат .nii Инициативы по нейровизуализации в области несжатых информационных технологий (NIfTI). В общей сложности обучающий набор состоит из 94 случаев, где каждый случай состоит из 7 типов. Компьютерная томография одного человека, такая как СТ, 4DPWI, CBF, CBV, MTT, Tmax и OT. Набор обучающих данных для обучения модели был разделен на две части: обучающую и валидационную, таким образом, модель будет обучена на обучающих данных и оценена с использованием данных валидации. После сеанса валидации мы отправляем тестовые данные, чтобы получить результат, на платформу ISLES для проверки. Инжир. На рис. 3.9 показан пример набора данных ISLES за 2018 год (компьютерная томография (КТ), мозговой кровоток (CBF), объем мозговой крови (CBV), среднее время прохождения (MTT), сегментарное изображение (OT), функция остатков ткани (Tmax)) [170, 179].

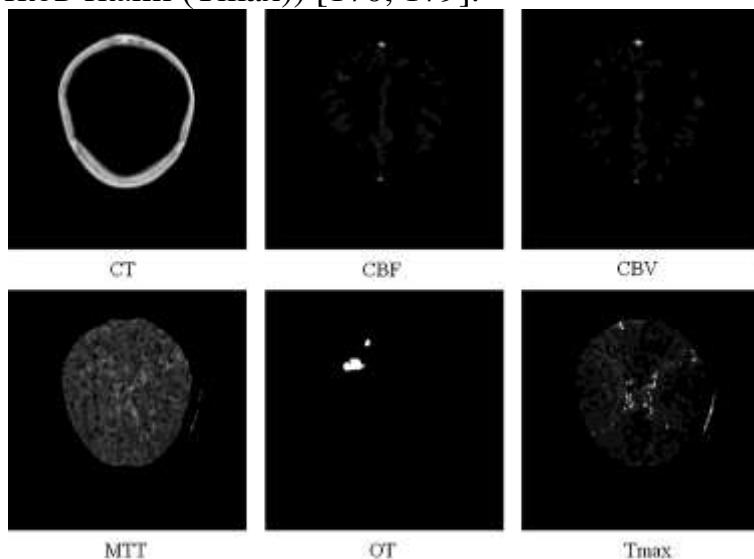


Рисунок 3.9 Выборка данных ISLES за 2018 год (компьютерная томография (КТ), мозговой кровоток (CBF), объем мозговой крови (CBV), среднее время прохождения (MTT), сегментарное изображение (OT), функция остатков ткани (Tmax))

### 3.4.3 Методы оценки модели глубокой нейронной сети на основе UNet для сегментации изображений головного мозга

В качестве оценки качества прогноза мы используем коэффициент сходства по шкале Dice/f1, точность, запоминаемость/чувствительность и индекс Жаккарда. Коэффициент сходства по шкале Dice/f1 отвечает за "схожесть" двух наборов данных. Пусть A и B - некоторые наборы вокселов (трехмерных пикселей). Формула (21) объясняет расчет коэффициента подобия очков Dice/f1 [46].

$$Dice(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (34)$$

В нашей задаче  $|A|$  - это реальный объем ядра штриха,  $|B|$  - прогнозируемый объем ядра штриха, а  $|A \cap B|$  - объем пересечения точек A и B. Мы видим, что для идеального предсказания  $Dice(A, B) = 1$ , а для наихудшего прогноза  $Dice(A, B) = 0$ . Поэтому мы постараемся максимально увеличить количество очков в Dice/ f1.

Однако важно отметить, что из-за того, что оценка Dice/f1 является недифференцированной метрикой, ее максимизация градиентными методами напрямую невозможна. Поэтому мы минимизируем стандартную метрику перекрестной энтропии (logloss), где метка класса равна единице, если вокsel принадлежит к затронутой области, и нулю в противном случае. Нейронная сеть выдает вероятность принадлежности банкноты к определенному классу.

Чтобы определить, является ли предсказание правильным в отношении объекта или нет, используется индекс Жаккарда (также называемый пересечением через объединение). Формула (22) демонстрирует расчет индекса Жаккарда [46].

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (35)$$

Точность эффективно описывает чистоту наших положительных обнаружений по отношению к достоверности данных о грунте. Сколько объектов, которые мы предсказали на данном изображении, на самом деле имели соответствующую аннотацию к достоверности данных о грунте? Формула (23) описывает точность [47].

$$precision = \frac{TP}{TP + FP} \quad (36)$$

Здесь TP - истинные срабатывания, FP - ложные срабатывания.

Отзывчивость или чувствительность эффективно описывает полноту наших положительных прогнозов относительно основной истины. Сколько из всех выражений, приведенных в нашей основной истине, мы отнесли к положительным прогнозам? [47]

$$recall = \frac{TP}{TP + FN} \quad (37)$$

Здесь ТР - истинно положительные результаты, FN - ложноотрицательные.

### 3.4.4 Основные математические формулы

Основные математические формулы для предлагаемой модели сегментации на основе UNet

Входное изображение:  $X$  размером (5, 128, 128, 32)

$X = [x_{i,j,k,l}]$ ,  $i = 1, \dots, 5$  (количество образцов),  $j = 1, \dots, 128$  (высота),  $k = 1, \dots, 128$  (ширина),  $l = 1, \dots, 32$  (количество срезов КТ)

Сверточный слой:

$$Y = Conv3D(X, W) + b \quad (38)$$

$W = [w_{m,n,o,p,q}]$ , где  $m, n, o$  – размеры фильтра,  $p$  – входные каналы,  $q$  – выходные каналы(фильтры).

$b = [b_q]$  – смешение для каждого фильтра.

$$Y = [y_{i,j,k,q}], \text{ где } y_{i,j,k,q} = \sum_{m,n,o,p} x_{i,2j+m,2k+n,2l+o,p} \cdot w_{m,n,o,p,q} + b_q$$

Функция активации:

$$Z = ReLU(Y) \quad (39)$$

$$Z = [z_{i,j,k,q}], \text{ где } z_{i,j,k,q} = \max(0, y_{i,j,k,q})$$

Пулинг (downsampling):

$$P = MaxPooling3D(Z, pool\_size = (2,2,2)) \quad (40)$$

$$P = [p_{i,j,k,q}], \text{ где } p_{i,j,k,q} = \max_{m,n,o} z_{i,2j+m,2k+n,2l+o,q}$$

$$j = 1, \dots, 32, k = 1, \dots, 32, l = 1, \dots, 8$$

Увеличение выборки (upsampling):

$$U = UpSampling3D(P, size = (2,2,2)) \quad (41)$$

$U = [u_{i,j,k,q}]$ , где  $u_{i,2j,2k,2l,q} = p_{i,j,k,l,q}$  (дублирование значений для увеличения размерности)

$$j = 1, \dots, 32, k = 1, \dots, 32, l = 1, \dots, 8$$

Конкатенация (concatenation):

$$C = Concatenate(U, Z) \quad (42)$$

$$C = [c_{i,j,k,q}]$$

Выходной сверточный слой:

$$O = Conv3D(C, W_{out}) + b_{out} \quad (43)$$

$$W_{out} = [w_{out,m,n,o,p,q}]$$

$$b_{out} = [b_{out,q}]$$

$$O = [o_{i,j,k,q}], \text{ где } o_{i,j,k,q} = \sum_{m,n,o,p} c_{i,2j+m,2k+n,2l+o,p} \cdot w_{out,m,n,o,p,q} + b_{out,q}$$

Размер  $O$ : (1,128,128,32,  $N_{classes}$ )

Функция активации выходного слоя:

$$\hat{Y} = Softmax(O) \quad (44)$$

$$\hat{Y} = [\hat{y}_{i,j,k,q}], \text{ где } \hat{y}_{i,j,k,q} = \frac{\exp(o_{i,j,k,q})}{\sum_q \exp(o_{i,j,k,q})}$$

Размер  $\hat{Y}$ :  $(1, 128, 128, 32, N_{classes})$

Эти детализированные шаги и раскрытые формулы по векторам, с использованием сверточного слоя с ядром 3x3x3 и шагом 2, описывают структуру 3D U-Net модели и процесс обработки данных на каждом этапе

## **4. РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ**

### **4.1 Экспериментальные результаты применения Интернета медицинских вещей для диагностики инсульта**

Для исследовательской работы был использован микроконтроллер Raspberry Pi 4, который отличается повышенной производительностью, большим объемом оперативной памяти и улучшенными сетевыми возможностями. Поскольку Raspberry Pi 4 используется в самых разнообразных проектах и приложениях, начиная от обучения программированию и заканчивая сложными проектами Интернета вещей (IoT), а также в качестве платформы для экспериментов и создания прототипов в области электроники и робототехники, благодаря своим улучшенным эксплуатационным характеристикам и способности справляться с более сложными задачами, он был выбран в качестве основного оборудования. Для получения данных о скорости кровотока с помощью эффекта Допплера использовался ультразвуковой датчик непрерывного действия. Допплер CW непрерывно излучает и принимает ультразвуковые сигналы. Это позволяет точно измерять скорость кровотока в глубоких сосудах и на высоких скоростях, где другие методы могут быть менее эффективными. Ультразвуковой датчик оценивает кровоток в крупных артериях и венах, включая сонные артерии, для выявления стеноза, тромбоза и других аномалий. Благодаря непрерывной передаче и приему ультразвуковых волн обеспечивается высокая точность измерения скорости кровотока. Благодаря непрерывной волне датчик прост в использовании для определенных типов измерений.

Подключение ультразвукового доплеровского датчика непрерывного действия (CW) к микроконтроллеру Raspberry Pi 4 осуществляется с помощью аналого-цифрового преобразователя (АЦП). Непрерывный доплеровский датчик непрерывно излучает и принимает ультразвуковые волны, а также посылает аналоговые сигналы, позволяя измерять скорость кровотока в сонной артерии [167]. АЦП, подключенный к Raspberry Pi, облегчает преобразование аналогового сигнала в цифровой. Этот преобразователь подключен к портам GPIO (ввода-вывода общего назначения) Raspberry Pi с одной стороны и к проводам датчиков - с другой. При исследовании сонной артерии на шее пациента микроконтроллер собирает данные о скорости кровотока по артериям. Эти данные отправляются в Raspberry pi, где полученные результаты сравниваются с нормами скорости кровотока в сонной артерии с целью выявления признаков инсульта, формируются в виде отчета и отправляются по Интернету к нейрохирургу. Рис. 4.1 иллюстрирует прототип платформы для ранней диагностики инсульта с использованием непрерывного допплеровского датчика. Для сканирования сонной артерии с помощью датчика CW применяется УЗИ гель, далее полученные результаты sistолической и средней скорости высвечиваются на подключенном экране прототипа.

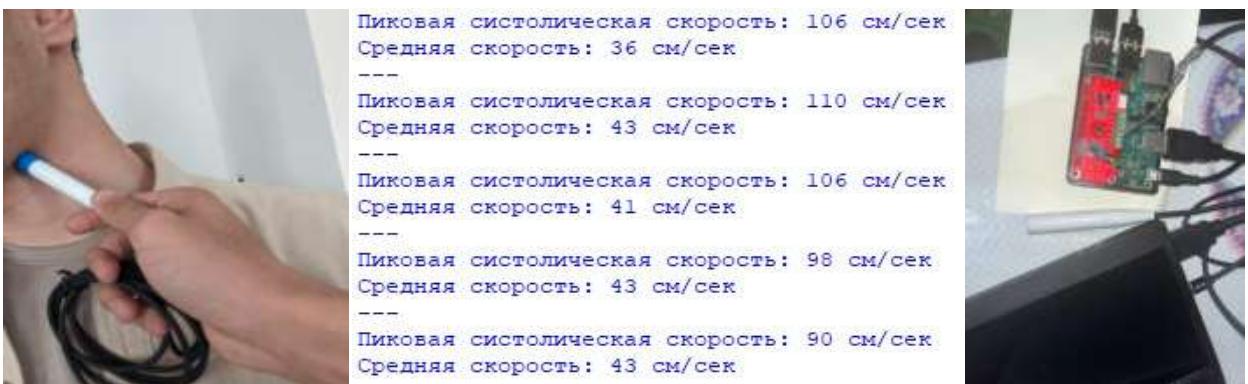


Рисунок 4.1. Прототип платформы для ранней диагностики инсульта с непрерывным ультразвуковым датчиком

Диагностика на ранней стадии с использованием ультразвукового датчика непрерывного действия неинвазивна, безопасна, проста в использовании и портативна. Портативная диагностика инсульта с использованием ультразвукового датчика непрерывного действия представляет собой передовую технологию, которая может сыграть ключевую роль в раннем выявлении и оценке инсультов, особенно в ситуациях, когда доступ к традиционным больничным ультразвуковым системам ограничен или недоступен. Такие портативные системы могут быть особенно полезны в службах неотложной медицинской помощи, удаленных районах и клинических учреждениях, где требуется немедленная диагностика.

Ранняя диагностика инсульта является ключевым аспектом в снижении тяжести последствий и улучшении прогноза для пациента. Неинвазивные методы диагностики, такие как использование непрерывного волнового допплеровского датчика для измерения скорости кровотока в сонной артерии, представляют собой значительный прогресс в области медицинских технологий. Этот метод позволяет оценить состояние кровотока и выявить потенциальные нарушения, которые могут указывать на риск развития инсульта.

Эффективность неинвазивного метода диагностики инсульта с использованием ультразвукового датчика непрерывной волны (CW), интегрированного с микроконтроллером Raspberry Pi в раннем выявлении признаков инсульта, основанного на анализе скорости кровотока по сонной артерии, открывает новые горизонты в профилактической медицине и диагностике. Преимущества использования предложенной технологии не ограничиваются возможностью раннего выявления инсульта, но также включают доступность, мобильность и простоту использования, что позволяет сократить время диагностики, что делает ее особенно ценной для применения в условиях, когда традиционные методы диагностики недоступны или неэффективны.

Применение непрерывного допплеровского датчика обеспечивает высокую точность измерений, оперативность получения результатов и отсутствие необходимости в непосредственном контакте с внутренними органами пациента, что делает процедуру безопасной и комфортной. Кроме

того, неинвазивность метода позволяет проводить скрининг больших групп населения с целью раннего выявления лиц с высоким риском развития инсульта.

#### **4.2 Результаты эксперимента модели для классификации мозговых инсультов с применением глубокого обучения**

В этом разделе демонстрируются результаты использования CNN для классификации мозговых инсультов с использованием различных параметров оценки, таких как точность, повторение, F-балл, и мы используем матрицу смешивания, чтобы показать истинно положительные, истинно отрицательные, ложноположительные и ложноотрицательные значения. Кроме того, мы сравнили использованный CNN с результатами других исследований.

На рис. 4.2 показаны показатели точности и запоминания, полученные за 10 эпох. Недостаточное обучение модели показало плохие результаты на начальном этапе.

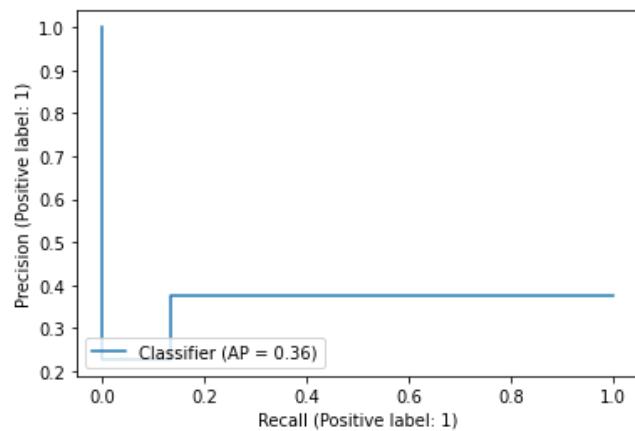


Рисунок 4.2 Точность и отзыв для 10 эпох

На рис. 4.3 показаны показатели точности и потерь обученной модели. На следующем этапе модель CNN была обучена на 35 эпохах, и результаты были следующими: потери: 0,5575 - точность: 0,7024 - val\_loss: 0,5602 - val\_accuracy: 0,7228 - lr: 9,0000e-05. Показатели валидации и потери класса обучения падают ниже 0,6, в то время как точность валидации и обучения, как правило, повышается с каждой эпохой, скорость обучения, как правило, близка к нулю.

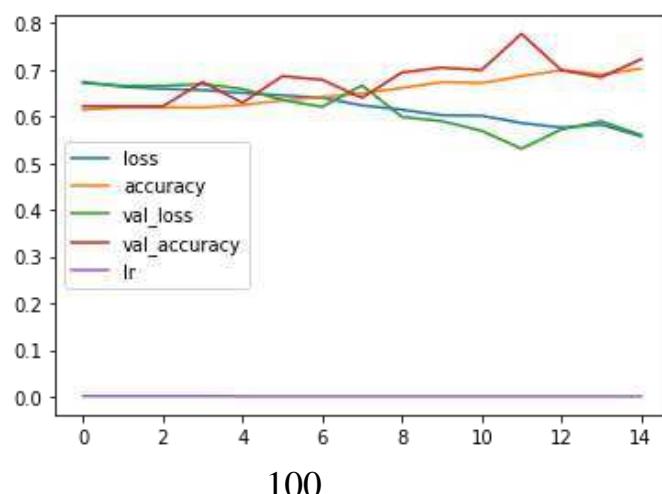


Рисунок 4.3 Потери при обучении и валидации во время обучения модели за 200 эпох

В результате точность теста составила 81%, а на рисунке 4.4 показана матрица путаницы для бинарной классификации мозговых инсультов, которая позволяет наглядно представить результаты работы классификатора. Здесь мы рассмотрим два случая: инсульт и без инсульта. На рисунке показаны реальные случаи инсульта в норме и прогнозируемые случаи инсульта в норме. Как вы можете видеть на рисунке ниже, 273 случая из 313 были предсказаны как нормальные, поскольку имеется нормальное компьютерное изображение, что означает действительно положительные случаи. Из 313 входных изображений в 134 действительно отрицательных случаях модель предсказывает инсульт по сравнению с обычной компьютерной томографией. Имеется 55 ложноотрицательных случаев, когда модель вернула нормальное изображение в случае инсульта, и 40 ложноположительных случаев, когда модель перенесла инсульт в отсутствие инсульта. Основываясь на полученных параметрах матрицы смешивания, мы получаем следующие оценочные параметры, такие как точность, прецизионность, отзывчивость и показатель F1, которые приведены в таблице 4.1.

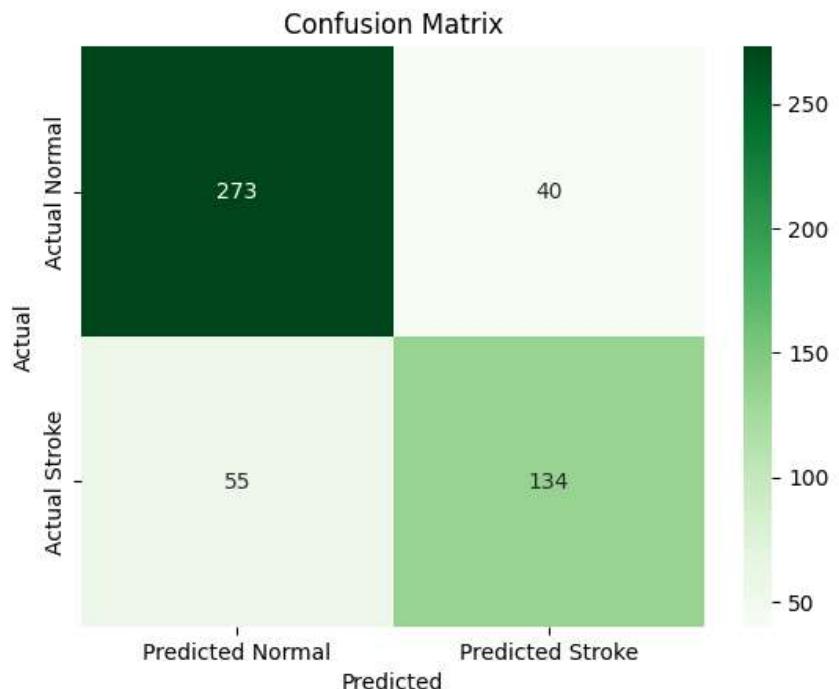


Рисунок 4.4 Матрица путаницы для классификации мозговых инсультов

Таблица 4.1: Результаты обучения и тестирования

	Прецизность	Отзыв	F1-счет	Поддержка
Нормальный	0.832317	0.872204	0.851794	313.000000
Инсульт	0.770115	0.708995	0.738292	189.000000
Точность	-	-	0.810757	0.810757
Среднее значение макроса	0.801216	0.790600	0.795043	502.000000
Взвешенное среднее	0.808898	0.810757	0.809061	502.000000

значение					
----------	--	--	--	--	--

В таблице 4.2 показано сравнение исследований по классификации и прогнозированию инсульта с точки зрения различных параметров оценки, таких как точность, прецизионность, запоминание и f-балл. Кроме того, в таблице представлена информация об используемых методах, а также о наборе данных, который использовался в этих исследованиях.

Таблица 4.2: Результаты обучения и тестирования

Ссылка	Метод	Набор данных	Точность	Прецизионность	Отзыв	F-счет
<b>Предлагаемая модель</b>	<b>CNN</b>	<b>CT images</b>	<b>81%</b>	<b>83%</b>	<b>87%</b>	<b>85%</b>
Sailasya and Kumari, 2021, [48]	LR	Kaggle table	78%	77.5%	77.6%	77.6%
Sailasya and Kumari, 2021, [48]	Decision Tree	Kaggle table	66%	77.5%	77.5%	77.6%
Sailasya and Kumari, 2021, [48]	RF	Kaggle table	73%	72%	73.5%	72.7%
Dev et al., 2022, [49]	SVM	Kaggle EMR	68%	67%	68%	68%
Dev et al., 2022, [49]	RF	Kaggle EMR	74%	74%	73%	73%
Dev et al., 2022, [49]	CNN	Kaggle EMR	74%	74%	72%	73%
Gautam and Raman, 2021, [50]	P_CNN_WP	2D CT	92%	92%	-	-
Gautam and Raman, 2021, [50]	P_CNN	2D CT	93%	93%	-	-
Lo et al., 2021 [51]	AlexNet	CT images	81%	-	-	-
Lo et al., 2021, [51]	ResNet-101	CT Images	80.89%	-	-	-
Pan et al., 2021, [52]	Residual Network	CT Images	80%	-	-	-
Nwosu et al., 2019, [53]	Decision Tree	CT Images	74.31%	-	-	-
Nwosu et al., 2019, [53]	Random Forest	CT Images	74.53%	-	-	-
Nwosu et al., 2019, [53]	Neural Network	CT Images	75.02%	-	-	-
Al-Shammari et al., 2021, [54]	Deep Neural Network	CT Images	79%	-	-	-

Очевидно, что полученные результаты доказывают эффективность CNN в классификации мозговых инсультов на КТ-снимках. Существуют различные методы, использующие различные наборы данных, такие как Kaggle, электронные медицинские карты Kaggle (Kaggle EMR), набор данных 2D КТ и набор данных КТ-изображений, которые были применены для классификации инсульта. Поскольку трудно изменять результаты, используя разные наборы данных, мы включили текущие результаты, используя набор данных компьютерной томографии [51-54].

Для демонстрации модели было создано веб-приложение на python с использованием ngrok и streamline. На рис. 4.5 показано, что в веб-приложение загружается рисунок мозга, затем модель CNN выполняет классификацию и выдает ответ на основе результатов моделирования. В данном случае модель правильно определила класс чертежа как обычный с точностью до 79%. Для демонстрации модели было создано веб-приложение на python с использованием ngrok и streamline. На рисунке 10 показано, что рисунок brain загружается в веб-приложение, затем модель CNN выполняет классификацию и выдает ответ на основе результатов моделирования. В этом случае модель правильно определила класс рисунка как обычный с точностью 79%.

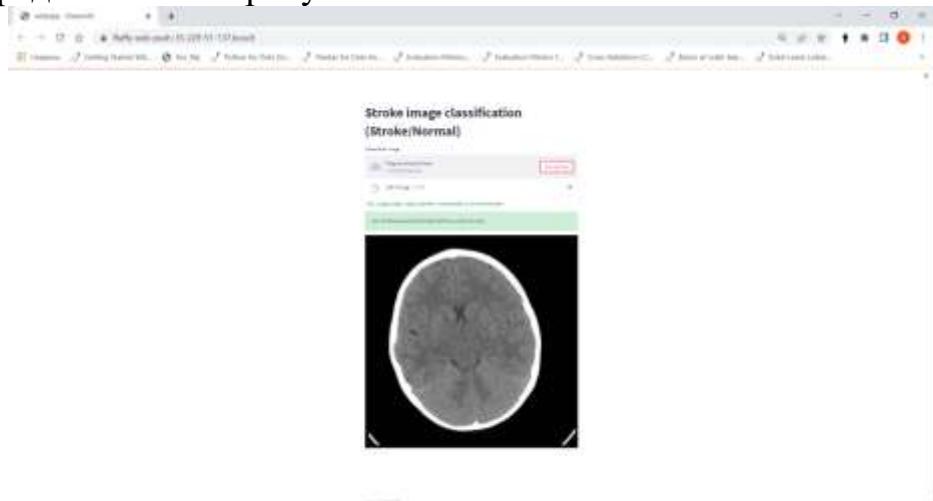


Рисунок 4.5 Веб-приложение для классификации инсультов на основе модели CNN

Полученные результаты демонстрируют эффективность сверточных нейронных сетей в оказании помощи неврологам в классификации типов инсульта на основе результатов компьютерной томографии головы. На достигнутую точность также влияет количество точек данных, полученных для обучающей выборки. В ходе этого исследования мы обнаружили, что предложенная нами система автоматизированной диагностики на основе сверточной нейронной сети может оценивать изображения, полученные с помощью компьютерной томографии, с точностью более 80%. Разработав классификацию инсульта на основе CNN, мы выполнили часть запланированной нами комплексной системы диагностики мозговых инсультов.

Другие подходы к идентификации инсульта могут быть использованы в будущих исследованиях и сравнены со сверточной нейронной сетью. В частности, методы выделения признаков могут быть использованы для предоставления нейронной сети определенных визуальных сигналов. В следующей части нашего исследования мы планируем разработать сложную систему, состоящую из трех этапов: обнаружение, классификация и сегментация. Процесс обнаружения инсульта основан на Интернете вещей, который использует датчик непрерывного действия wave-4 (CW-4), измеряющий скорость кровотока в сонных артериях, и микроконтроллер Arduino. Процесс классификации выполняется с помощью CNN на основе компьютерной томографии головы.

### 4.3 Результаты эксперимента модели глубокой нейронной сети на основе UNet для сегментации изображений головного мозга

Для экспериментальной работы мы использовали классическую архитектуру U-Net с набором данных ISLES 2018. Практическая часть эксперимента проводилась в среде Google colab с использованием библиотеки Tensorflow. Классическая модель UNet была завершена через 200 эпох, так как она была плохо обучена, а потеря валидации ничего не изменила и была неинформативной. Наша модифицированная модель также была реализована в среде Google colab, но из-за нехватки памяти и мощности платформы наша модель остановилась на уровне 650 эпох.

На рисунке 4.6 показаны сравнительные потери при обучении и валидации модели в течение 200 эпох классической 3D-модели UNet, где максимальная шкала потерь равна 1,0, потери при обучении равны 0,222, а потери при верификации равны 0,410.

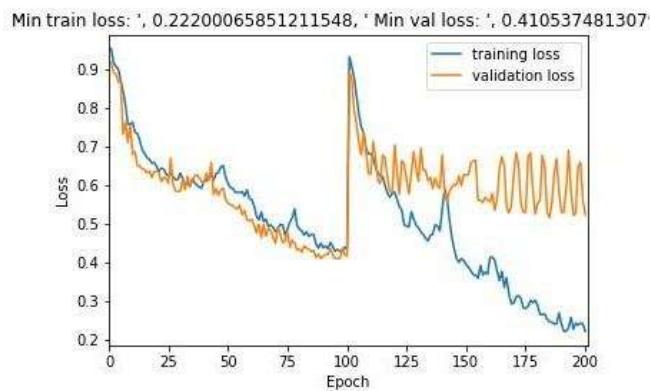


Рисунок 4.6: Потери при обучении и валидации во время обучения модели за 200 эпох

На рисунке 4.7 показано, что обучение для предложенной модели было начато через 650 эпох, по сравнению с классической 3D-моделью UNet, процесс потери происходил равномерно с небольшими колебаниями, и результаты для потери при обучении составляют 0,618, а для валидации - 0,620.

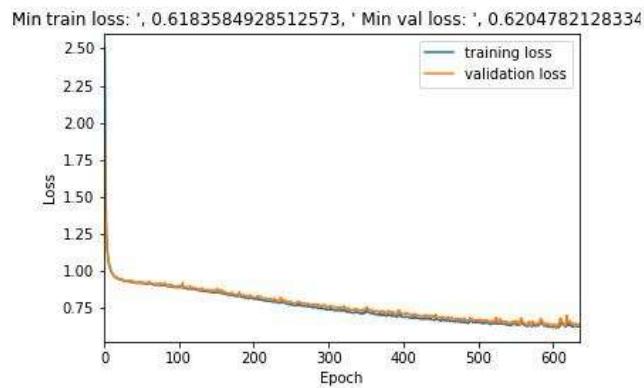


Рисунок 4.7: Потери при обучении и валидации во время обучения модели за 650 эпох

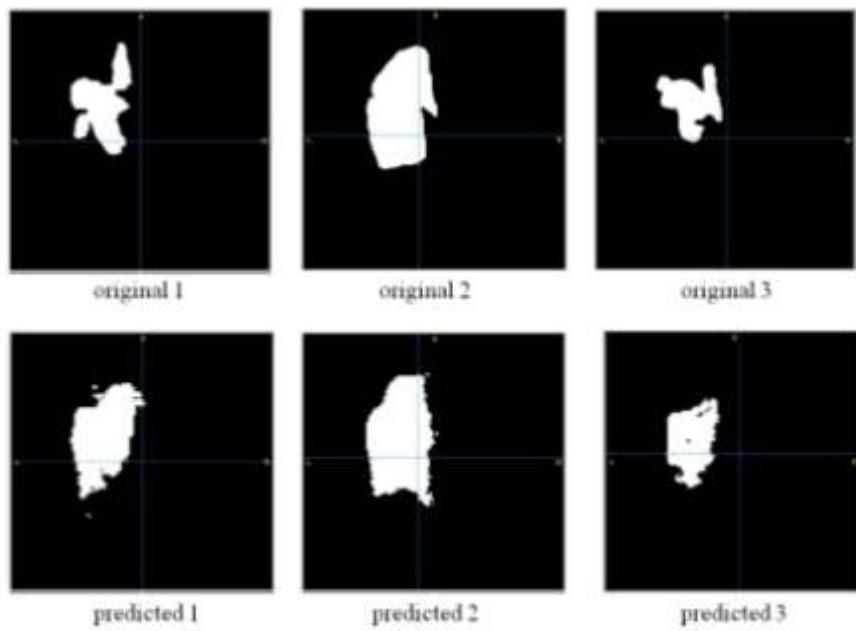


Рисунок 4.8 Результаты сегментации мозгового инсульта. Изображения в первой строке - исходные изображения; изображения во второй строке - изображения после применения сегментации)

На рисунке 4.8 показаны три примера исходных сегментированных изображений и прогнозируемых изображений предложенной модели. Изначально исходные изображения были высокого качества, но для того, чтобы количество параметров NN было меньше для расчетов в Google colab, исходное изображение пришлось сжать, поэтому, поскольку качество изображения хуже, прогнозируемые изображения отличаются от исходного.

Таблица 4.3: Результаты обучения и тестирования

Методы	Классический 3D UNet (результаты обучения)	Классический 3D UNet (Результаты теста)	Proposed approach (Training results)	Proposed approach (Test results)
Dice/f1 счет	48%	36%	90%	58%
Точность	39%	38%	83%	68%
Отзывчивость/чувствительность	99%	37%	93%	60%
Индекс Жаккарда	35%	32%	89%	66%

В таблице 4.3 представлены результаты сравнения по четырем критериям оценки предложенной нами модели и классической модели UNet. Результаты показывают, что предложенная модель превосходит классическую модель UNet в задаче сегментации штрихов. Хотя результаты обучения показывают в среднем 90%, результаты тестирования демонстрируют гораздо более низкую производительность. Этот результат объясняется небольшим объемом данных, поскольку объем данных об обучении и тестировании был критически важен.

В таблице 4.4 сравнивается предложенная 3D-модель UNet с другими современными моделями. Предложенная архитектура показала высокую производительность по сравнению с другими моделями. Хотя мы должны

отметить, что в сравниваемых моделях использовались разные наборы данных для обучения и тестирования их архитектуры. Несмотря на это, данная модель демонстрирует высокую производительность по всем параметрам оценки, включая коэффициент сходства баллов dice/f1, точность и запоминаемость/чувствительность.

Таблица 4.4: Сравнение предлагаемого модельного тестового набора с современными моделями

Методы	Dice/f1 счет	Точность	Отзывчивость/чувствительность
<b>Предлагаемая модель</b>	<b>0.58</b>	<b>0.68</b>	<b>0.60</b>
D-UNET [14]	0.53	0.63	0.52
X-NET [26]	0.48	0.60	0.47
U-NET CNN [32]	0.46	0.34	0.44
SegNet [34]	0.27	0.19	0.25
PSPNet [45]	0.35	0.25	0.33
V-NET [48]	0.43	0.50	0.49
DeepLab v3+ [49]	0.46	0.34	0.44
ResUNET [50]	0.47	0.35	0.45
2D Dense-UNET [51]	0.47	0.35	0.48

Внедрение в клиническую практику системы поддержки принятия решений, которая значительно ускорит и повысит эффективность оказания медицинской помощи при мозговом инсульте, является важной задачей. Автоматический анализ данных нейровизуализации позволит в кратчайшие сроки провести раннюю дифференциальную диагностику, спрогнозировать возможный исход заболевания и дать рекомендации по наиболее эффективному методу лечения индивидуально для каждого пациента. Наличие репрезентативной выборки, состоящей из большого количества структурированных и достоверных данных, является основой для реализации различных методов анализа медицинских изображений, в том числе с использованием машинного обучения. Эффективность и точность моделей также напрямую зависят от качества исходных данных (обучающей выборки) и требуют их тщательной предварительной обработки [52].

При проведении исследования возникает необходимость в поиске случаев, соответствующих выбранным критериям, в локальных хранилищах одного медицинского учреждения с последующим трудоемким процессом пометки изображений экспертами вручную. Именно по этой причине образцы, используемые в обучающих системах, чаще всего содержат менее 100 диагностических серий [53].

Несмотря на актуальность автоматизации процесса диагностики ишемического инсульта, наличие соответствующих коллекций изображений в открытом доступе в мире немногочисленно, а во многих странах такие проекты полностью отсутствуют, что неизбежно приводит к потере точности моделей, получаемых на открытых популяционных данных. Наиболее распространенной целью организаций общедоступных наборов данных является, главным

образом, оказание помощи командам в создании и совершенствовании алгоритмов автоматической сегментации объема поражения, и часто коллекции представлены диагностическими данными для ишемического и геморрагического инсульта [53-55] или изображениями с уже развившимися обширными участками ишемии (не включают случаи в острой стадии). период), и практически не содержат клинической информации о пациенте. Некоторые наборы данных не содержат маркировки поражений или размечены с использованием алгоритмов автоматической сегментации без участия экспертов, что делает невозможным их использование в качестве обучающей выборки без предварительной обработки. Несомненно, системы для экстренной и ранней диагностики пациентов с ИИ наиболее актуальны, но на данный момент трудно найти данные для их разработки. Более того, такие крупные проекты, посвященные ишемическим поражениям, как ENIGMA Stroke Recovery [56], ATLAS [57], а также конкурс ISLES competition [30], проводившийся в 2016-2018 годах, сосредоточены исключительно на сборе данных магнитно-резонансной томографии и определенных видах функциональных исследований мозга. Изображения этих методов, несомненно, очень информативны для принятия клинических решений, но они не являются широко используемыми методами диагностики инсульта. Другим распространенным недостатком общедоступных наборов изображений является их размещение в сжатом виде или предварительное преобразование в форматы с потерей качества и метаданных, что существенно ограничивает исследователей в выборе методов анализа.

Сегментация изображений мозга до сих пор не является полностью решенной проблемой в области глубокого обучения. Количество доступных в исследовании материалов, включая данные обучения и тестирования, также играет ключевую роль в сегментации изображений. В этой статье мы предложили модифицированную архитектуру UNet для сегментации очагов острого ишемического инсульта. В свою очередь, модель UNet является одним из лучших методов сегментации медицинских изображений, применяемых к небольшим объемам данных. Кроме того, предложенная нами усовершенствованная модель помогает повысить точность сегментации КТ-изображений, что приводит к лучшим результатам. В частности, предложенная модель достигла коэффициента подобия кубов в 58%, отзывчивости/чувствительности в 60%, что доказывает правильность используемых технологий, таких как: увеличение данных для увеличения обучающих данных, отсев для предотвращения совместной адаптации пикселей с их соседями на картах объектов, удаление всех карт объектов из сверточного слоя, эффективный оптимизатор Adam, l2-регулирование для решения задач мультиколлинеарности. В качестве будущей работы мы рассматриваем усовершенствование предложенной модели путем применения тонкой настройки и извлечения функций. Он также предназначен для создания наших собственных весов в наборе данных ISLES 2017, что улучшит нашу модель за счет корректировки слоев, которые имеют наиболее абстрактные

представления, и для более эффективных моделей в будущем будет применяться извлечение объектов, что является одним из основных ключевых моментов. Таким образом, мы считаем, что использование этих методов повысит точность критериев оценки и приблизит процесс сегментации к высокой точности.

#### **4.4 Результаты эксперимента модели глубокой нейронной сети на основе UNet для сегментации изображений головного мозга с блоками ResNet**

В ходе обучения моделей были получены результаты обучения и проверки потерь в виде линейного графика, которые показаны на рисунке 4.9.

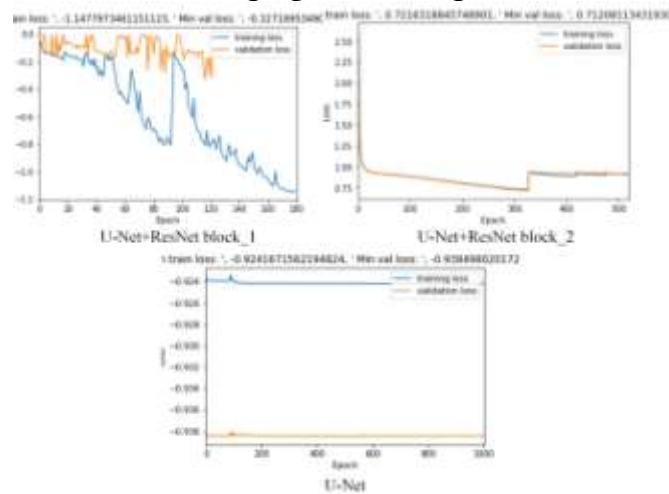


Рисунок 4.9 Результаты обучения и проверки работоспособности трех моделей (U-Net+ResNetblock\_1, U-Net+ResNetblock\_2 и U-Net)

Результат получается путем отправки полученных результатов тестирования в smir. Для каждой модели были получены результаты измерений Dice, расстояния Хаусдорфа, среднего расстояния, точности, отзыва и AVD. В таблице 4.5 приведены результаты для каждой модели.

Таблица 4.5: Сравнительные результаты для каждой модели

Модель	Dice	Расстояние Хаусдорфа	Среднее расстояние	Точность	Отзыв	AVD
U-Net+ResNet block_1	0.09	19354907.28	19354854.75	0.06	0.25	34.93
U-Net+ResNet block_2	0.10	19354903.82	19354854.08	0.14	0.13	45.85
U-Net	0.31	19354901.36	19354848.45	0.36	0.35	19.23

Далее, на рисунках 4.10, 4.11, 4.12 представлены сравнительные результаты исходных рисунков очагов сегментации штрихов и прогнозируемых результатов.

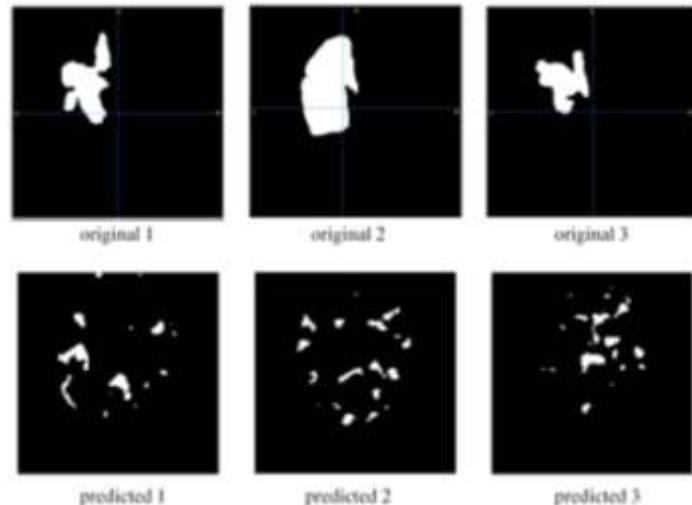


Рисунок 4.10 Прогнозируемые результаты сегментации хода по модели U-Net+ResNet block\_1

Как видно на рисунке 4.10, сегментирование фокусов обводки с использованием UNet+ResNetblock\_1 дало неточный результат.

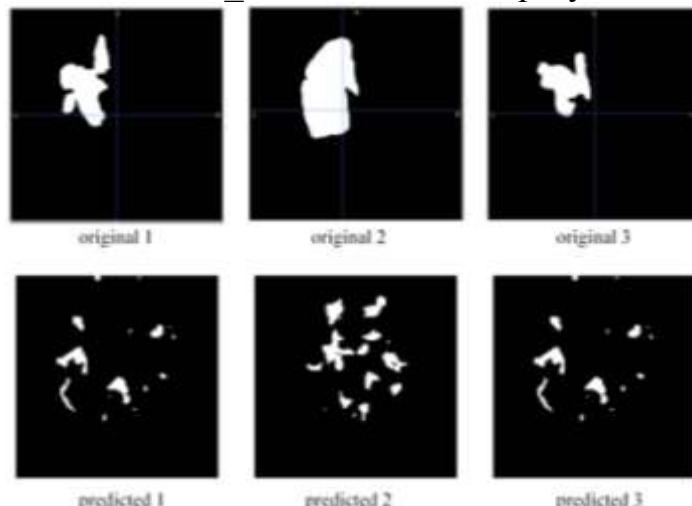


Рисунок 4.11 Прогнозируемые результаты сегментации хода по модели U-Net+ResNet block\_2

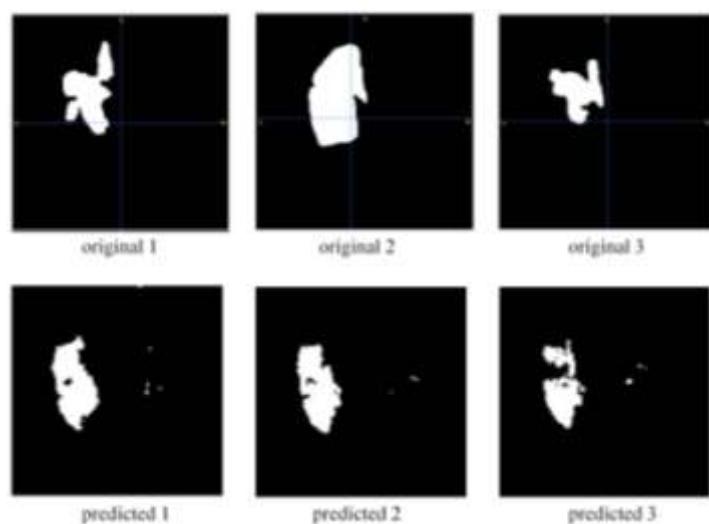


Рисунок 4.12 Прогнозируемые результаты сегментации штрихов по модели U-Net

В результате эксперимента выяснилось, что как в первом, так и во втором случае использование блоков ResNet дало низкий результат по сравнению с модифицированной моделью U-Net. Таким образом, мы определили для себя, что объединение блоков разных моделей дает более низкий результат, чем использование совершенно отдельной модели, такой как в нашем случае модифицированная U-Net.

Внедрение систем рекомендаций в клинические исследования является важнейшим мероприятием, которое значительно ускорит и повысит эффективность терапевтического лечения нарушений мозгового кровообращения. Автоматизированная классификация и обработка нейровизуализаций позволяют проводить быструю дифференциированную диагностику, прогнозировать вероятные исходы заболевания и давать персонализированные рекомендации по одному из наиболее важных вариантов лечения для пациентов. Наличие репрезентативной группы, состоящей из значительного количества организованных и точных данных, служит основой для внедрения различных методов компьютерной диагностики, включающих когнитивные вычисления и искусственный интеллект. Эффективность и быстродействие алгоритмов также тесно связаны с качеством исходных данных или обучающего набора и требуют тщательной предварительной обработки [52].

При проведении исследования необходимо найти экземпляры, удовлетворяющие следующим условиям, в локальном хранилище конкретной больницы, после чего специалисты вручную помечают фотографии тегами, что требует много времени. Вот почему учебные материалы часто содержат чуть менее ста диагностических тестов [53].

Несмотря на важность автоматизированных систем выявления и лечения инсультов, глобальная доступность подходящих файлов изображений в открытом доступе ограничена, а во многих регионах мира подобные разработки полностью отсутствуют, что, по сути, приводит к потере точности моделей, построенных с использованием открытых статистических данных. Основная цель создания открытых наборов данных - помочь командам в совершенствовании методологий полностью автоматизированного обнаружения и сегментации повреждений и управления ими. Часто образцы содержат клинические критерии цереброваскулярного заболевания [53-55] или изображения с установленными обширными областями ишемии и содержат мало клинических данных о пациенте. Некоторые образцы не содержат поражений или сегментируются автоматически без участия специалистов, что затрудняет их использование в качестве учебных образцов без предварительной обработки данных. Без оснований полагать, что раннее выявление популяции пациентов с помощью искусственного интеллекта имеет решающее значение, но данных, позволяющих это сделать, в настоящее время недостаточно. Кроме того, крупномасштабные проекты, полностью посвященные опухолям, вызванным ишемией головного мозга, такие как ENIGMA Stroke Recovery [56],

ATLAS [57], ISLES contest [30], которые проводились в период с 2016 по 2018 год, просто фокусируются на сборе данных МРТ и определенных типах базовых нейронных исследований. Хотя изображения, полученные с помощью этих технологий, очевидно, очень ценные для принятия медицинских решений, они нечасто используются для диагностики инсульта. Другой распространенной проблемой, связанной с коллекциями изображений, находящихся в открытом доступе, является их сжатие, а также переход к форматам, которые снижают качество и информативность, что значительно ограничивает выбор методов исследования.

Количество доступных материалов для исследования, включая данные обучения и тестирования, также играет ключевую роль в сегментации изображений. В данном разделе предложена комбинированная и модифицированная модели UNet для сегментации очагов острого ишемического инсульта. В свою очередь, модель UNet является одним из лучших методов сегментации медицинских изображений, применяемых к небольшим объемам данных. Кроме того, одна из экспериментальных моделей помогла повысить точность сегментации компьютерных изображений, что приводит к лучшим результатам. В частности, лучшая модель, предложенная нами в ходе эксперимента, достигла коэффициента dice 31%, чувствительности к запоминанию 35%, что доказывает правильность используемых технологий, таких как: увеличение данных для увеличения обучающих данных, экранирование для предотвращения совместной адаптации пикселей с их соседями на картах объектов, удаление всех карт объектов с карт памяти, сверточный слой, эффективный оптимизатор Adam, регулирование 12 для задач мультиколлинеарности. В качестве будущей работы мы рассматриваем усовершенствование модели leader путем применения тонкой настройки и извлечения функций. Он также предназначен для создания наших собственных весов в наборе данных ISLES 2017, что улучшит нашу модель, настроив слои с наиболее абстрактными представлениями, а для более эффективных моделей в будущем будет применено извлечение объектов, что является одним из основных ключевых моментов. Таким образом, мы считаем, что использование этих методов повысит точность критериев оценки и приблизит процесс сегментации к высокой точности.

## **ЗАКЛЮЧЕНИЕ**

За последние годы число людей, перенесших инсульт, резко возросло, и в настоящее время это является серьезной проблемой общественного здравоохранения во всем мире. Условия жизни пациентов улучшаются по мере использования новейшего оборудования для диагностики и восстановления. В связи с этим, разработка методов ранней диагностики инсульта и точный анализ нейровизуализации является актуальной проблемой в сфере здравоохранения.

В ходе проведенных исследований были решены все поставленные задачи диссертационного исследования и получены следующие научные и практические результаты:

Диагностика инсульта в нашем подходе состоит из нескольких этапов, а именно:

1. Интернет медицинских вещей, где используя непрерывно-волновой датчик скорости кровотока измеряется скорость кровотока по сонной артерии, полученные данные отправляются по Wi-Fi в облако, где сверяется информация о кровотоке и выдает ответ обратно в платформу Интернета вещей, который соорудирован с мини-компьютера. Первый этап является мобильным, портативным.
2. Следующий этап диагностики на моделях глубокого обучения, новыми методами классификации. У любого пациента есть возможность загрузки изображения КТ головного мозга на веб платформу, где обученная модель глубокого обучения попробует распознать инсульт, и выдать ответ есть ли инсульт или нет.
3. На последнем этапе, пациент также может загрузить изображение своего КТ и получить сегментированную область пораженной области инсултом, без помощи специалиста.

Таким образом:

- Была разработана система для диагностики инсульта, объединяющая возможности Интернета медицинских вещей и глубокого обучения. Это позволило нам значительно повысить эффективность и точность диагностики инсультов.
- Был разработан прототип для ранней диагностики инсульта с применением датчика для измерения скорости кровотока в сонной артерии.
- Разработана технологическая схема прототипа оборудования для диагностики первых признаков инсульта.
- Разработана модель глубокого обучения для классификации инсульта по изображениям головного мозга, достигнув результатов со следующими показателями: accuracy-81%, precision-83%, полноты (recall-87%) и F1-меры (85%).

- Разработана глубокая U-Net модель для сегментации очагов инсульта на 3D-изображениях головного мозга, результаты при работе с небольшим объемом данных, достигнув результатов со следующими показателями: Dice коэффициента (0.58), точности (precision-0.68) и полноты (recall-0.60).

Также для ускорения процесса работы в будущем планируется разработка мобильных приложений для применения беспроводных ультразвуковых датчиков для измерения скорости кровотока по сонной артерии. Этот способ позволит полностью автоматизировать процесс диагностики инсульта, а также будет возможность применения пациентами данного оборудования и моделей независимо от специально обученных людей.

Дальнейшее направление настоящего исследования видится во внедрении скорой помощи для применения в диагностике инсульта.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- [1] Kochanek, K. D., Murphy, S. L., Xu, J., & Arias, E. (2019). Deaths: final data for 2017.
- [2] Campbell, B. C., De Silva, D. A., Macleod, M. R., Coutts, S. B., Schwamm, L. H., Davis, S. M., & Donnan, G. A. (2019). Ischaemic stroke. *Nature Reviews Disease Primers*, 5(1), 1-22.
- [3] Chtaou, N., Bouchal, S., Midaoui, A. E., Souirti, Z., Tachfouti, N., & Belahsen, M. F. (2020). Stroke Mimics: Experience of a Moroccan Stroke Unit. *Journal of Stroke and Cerebrovascular Diseases*, 29(5), 104651.
- [4] Allder SJ, Moody AR, Martel AL, Morgan PS, Delay GS, Gladman JR, Fentem P, Lennox GG. Limitations of clinical diagnosis in acute stroke. *Lancet*. 1999 Oct 30;354(9189):1523. [PubMed]
- [5] Shafaat, O., & Sotoudeh, H. (2019). Stroke Imaging. *StatPearls*.
- [6] Lee, E. J., Kim, Y. H., Kim, N., & Kang, D. W. (2017). Deep into the brain: artificial intelligence in stroke imaging. *Journal of stroke*, 19(3), 277.
- [7] Raghavendra, U., Acharya, U. R., & Adeli, H. (2019). Artificial Intelligence Techniques for Automated Diagnosis of Neurological Disorders. *European neurology*, 1-24.
- [8] Brouns, R., & De Deyn, P. P. (2009). The complexity of neurobiological processes in acute ischemic stroke. *Clinical neurology and neurosurgery*, 111(6), 483-495.
- [9] Saenger, A. K., & Christenson, R. H. (2010). Stroke biomarkers: progress and challenges for diagnosis, prognosis, differentiation, and treatment. *Clinical chemistry*, 56(1), 21-33.
- [10] Testai, F. D., & Aiyagari, V. (2008). Acute hemorrhagic stroke pathophysiology and medical interventions: blood pressure control, management of anticoagulant-associated brain hemorrhage and general management principles. *Neurologic clinics*, 26(4), 963-985.
- [11] Chandrabhatla, A. S., Kuo, E. A., Sokolowski, J. D., Kellogg, R. T., Park, M., & Mastorakos, P. (2023). Artificial Intelligence and Machine Learning in the Diagnosis and Management of Stroke: A Narrative Review of United States Food and Drug Administration-Approved Technologies. *Journal of Clinical Medicine*, 12(11), 3755.
- [12] Omarov, B., Altayeva, A., Turganbayeva, A., Abdulkarimova, G., Gusmanova, F., Sarbasova, A., ... & Omarov, N. (2019). Agent based modeling of smart grids in smart cities. In *Electronic Governance and Open Society: Challenges in Eurasia: 5th International Conference, EGOSE 2018, St. Petersburg, Russia, November 14-16, 2018, Revised Selected Papers 5* (pp. 3-13). Springer International Publishing.
- [13] Son, H., Lee, S., Kim, K., Koo, K. I., & Hwang, C. H. (2022). Deep learning-based quantitative estimation of lymphedema-induced fibrosis using three-dimensional computed tomography images. *Scientific Reports*, 12(1), 15371.
- [14] Madsen, T. E., Howard, V. J., Jiménez, M., Rexrode, K. M., Acelajado, M. C., Kleindorfer, D., & Chaturvedi, S. (2018). Impact of conventional stroke risk factors on stroke in women: an update. *Stroke*, 49(3), 536-542.

- [15] Xi, G., Keep, R. F., & Hoff, J. T. (2006). Mechanisms of brain injury after intracerebral haemorrhage. *The Lancet Neurology*, 5(1), 53-63.
- [16] Rohaut, B., Doyle, K. W., Reynolds, A. S., Igwe, K., Couch, C., Matory, A., ... & Park, S. (2019). Deep structural brain lesions associated with consciousness impairment early after hemorrhagic stroke. *Scientific reports*, 9(1), 1-9.
- [17] Li, X., Liu, H., Zeng, W., Liu, X., Wen, Y., Xiong, Q., & Yang, R. (2020). The Value of Whole-Brain Perfusion Parameters Combined with Multiphase Computed Tomography Angiography in Predicting Hemorrhagic Transformation in Ischemic Stroke. *Journal of Stroke and Cerebrovascular Diseases*, 29(4), 104690.
- [18] Schweitzer, A. D., Niogi, S. N., Whitlow, C. T., & Tsioris, A. J. (2019). Traumatic brain injury: imaging patterns and complications. *RadioGraphics*, 39(6), 1571-1595.
- [19] Scheitz, J. F., Nolte, C. H., Doecker, W., Hachinski, V., & Endres, M. (2018). Stroke-heart syndrome: clinical presentation and underlying mechanisms. *The Lancet Neurology*, 17(12), 1109-1120.
- [20] Fernandez-Mendoza, J., He, F., Vgontzas, A. N., Liao, D., & Bixler, E. O. (2019). Interplay of Objective Sleep Duration and Cardiovascular and Cerebrovascular Diseases on Cause-Specific Mortality. *Journal of the American Heart Association*, 8(20), e013043.
- [21] Kurisu, K., & Yenari, M. A. (2018). Therapeutic hypothermia for ischemic stroke; pathophysiology and future promise. *Neuropharmacology*, 134, 302-309.
- [22] Shinya, Y., Miyawaki, S., Kumagai, I., Sugiyama, T., Takenobu, A., Saito, N., & Teraoka, A. (2020). Risk Factors and Outcomes of Cerebral Stroke in End-Stage Renal Disease Patients Receiving Hemodialysis. *Journal of Stroke and Cerebrovascular Diseases*, 29(4), 104657.
- [23] Walsh, K., Grech, C., & Hill, K. (2019). Health advice and education given to overweight patients by primary care doctors and nurses: a scoping literature review. *Preventive medicine reports*.
- [24] Madsen, T. E., Howard, V. J., Jiménez, M., Rexrode, K. M., Acelajado, M. C., Kleindorfer, D., & Chaturvedi, S. (2018). Impact of conventional stroke risk factors on stroke in women: an update. *Stroke*, 49(3), 536-542.
- [25] Howard, V. J., Madsen, T. E., Kleindorfer, D. O., Judd, S. E., Rhodes, J. D., Soliman, E. Z., ... & Howard, G. (2019). Sex and race differences in the association of incident ischemic stroke with risk factors. *JAMA neurology*, 76(2), 179-186.
- [26] Méloux, A., Béjot, Y., Rochette, L., Cottin, Y., & Vergely, C. (2019). Brain-Heart Interactions During Ischemic Processes: Clinical and Experimental Evidences. *Stroke*, STROKEAHA-119.
- [27] Yamani, N., Chalmer, M. A., & Olesen, J. (2019). Migraine with brainstem aura: defining the core syndrome. *Brain*, 142(12), 3868-3875.
- [28] Jovin, T., & Caplan, L. R. (2016). Subarachnoid hemorrhage, aneurysms, and vascular malformations. *Caplan's Stroke: A Clinical Approach*. Saunders, 439.
- [29] Lian, Y., Zhu, Y., Tang, F., Yang, B., & Duan, R. (2017). Herpes zoster and the risk of ischemic and hemorrhagic stroke: A systematic review and meta-analysis. *PloS one*, 12(2).

- [30] Hodkin, E. F., Lei, Y., Humby, J., Glover, I. S., Choudhury, S., Kumar, H., ... & Jackson, A. (2018). Automated FES for upper limb rehabilitation following stroke and spinal cord injury. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(5), 1067-1074.
- [31] Wiersma, A. M., Fouad, K., & Winship, I. R. (2017). Enhancing spinal plasticity amplifies the benefits of rehabilitative training and improves recovery from stroke. *Journal of Neuroscience*, 37(45), 10983-10997.
- [32] Wong, A. W., Ng, S., Dashner, J., Baum, M. C., Hammel, J., Magasi, S., ... & Goldsmith, A. (2017). Relationships between environmental factors and participation in adults with traumatic brain injury, stroke, and spinal cord injury: a cross-sectional multi-center study. *Quality of life research*, 26(10), 2633-2645.
- [33] K. K. D. Ramesh, G. K. Kumar, K. Swapna, D. Datta and S. S. Rajest, “A review of medical image segmentation algorithms,” EAI Endorsed Transactions on Pervasive Health and Technology, pp. 1-9, 2021.
- [34] Y. Zhou, W. Huang, P. Dong, Y. Xia and S. Wang, “D-UNet: a dimension-fusion U shape network for chronic stroke lesion segmentation,” IEEE/ACM transactions on computational biology and bioinformatics, vol. 18, no. 3, pp. 940-950, 2021.
- [35] K. Kamnitsas, C. Ledig, V. F. J. Newcombe, J. P. Simpson, A. D. Kane et al., “Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation,” Medical image analysis, vol. 36, pp. 61-78, 2017.
- [36] W. Wu, Y. Lu, R. Mane and C. Guan, “Deep learning for neuroimaging segmentation with a novel data augmentation strategy,” in 2020 42nd Annual International Conference of the IEEE Engineering in Medicine \& Biology Society (EMBC), Montreal, QC, Canada, pp. 1516-1519, 2020.
- [37] S. Nazari-Farsani, M. Nyman, T. Karjalainen, M. Bucci, J. Isojarvi et al., “Automated segmentation of acute stroke lesions using a data-driven anomaly detection on diffusion weighted MRI,” Journal of neuroscience methods, vol. 333, pp. 108575, 2020.
- [38] N. Feng, X. Geng and L. Qin, “Study on MRI medical image segmentation technology based on CNN-CRF model,” IEEE Access, vol. 8, pp. 60505-60514, 2020.
- [39] L. Liu, S. Chen, F. Zhang, F. Wu, Y. Pan et al., “Deep convolutional neural network for automatically segmenting acute ischemic stroke lesion in multi-modality MRI,” Neural Computing and Applications, vol. 32, no. 11, pp. 6545-6558, 2020, 10.1007/s00521-019-04096-x
- [40] L. Chen, P. Bentley and D. Rueckert, “Fully automatic acute ischemic lesion segmentation in DWI using convolutional neural networks,” NeuroImage Clin, 2017, 10.1016/j.nicl.2017.06.016
- [41] T. Song, “Generative model-based ischemic stroke lesion segmentation,” arXiv preprint arXiv:1906.02392, 2019.
- [42] S.Wang, Z. Chen, W. Yu and B. Lei, “Brain stroke lesion segmentation using consistent perception generative adversarial network,” arXiv preprint arXiv:2008.13109, 2020.

- [43] N. K. Subbanna, D. Rajashekhar, B. Cheng, G. Thomalla, J. Fiehler et al., "Stroke lesion segmentation in FLAIR MRI datasets using customized Markov random fields," *Frontiers in neurology*, vol. 10, pp. 541, 2019, 10.3389/fneur.2019.00541
- [44] A. Subudhi, M. Dash and S. Sabut, "Automated segmentation and classification of brain stroke using expectation-maximization and random forest classifier," *Biocybernetics and Biomedical Engineering*, vol. 40, no. 1, pp. 277-289, 2020, 10.1016/j.bbe.2019.04.004
- [45] N. S. M. Noor, N. M. Saad, A. R. Abdullah and N. M. Ali, "Automated segmentation and classification technique for brain stroke," *International Journal of Electrical and Computer Engineering*, vol. 9, no. 3, pp. 1832, 2019, 10.11591/ijece.v9i3
- [46] K. Qi, H. Yang, C. Li, Z. Liu, M. Wang et al., "X-net: Brain stroke lesion segmentation based on depthwise separable convolution and long-range dependencies," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Shenzhen, China, pp. 247-255, 2019.
- [47] B. Zhao, Z. Liu, G. Liu, C. Cao, S. Jin et al., "Deep learning-based acute ischemic stroke lesion segmentation method on multimodal MR images using a few fully labeled subjects," *Computational and Mathematical Methods in Medicine*, vol. 2021, 2021, 10.1155/2021/3628179
- [48] Y. Wang, A. K. Katsaggelos, X. Wang and T. B. Parrish, "A deep symmetry convnet for stroke lesion segmentation," in *2016 IEEE International Conference on Image Processing (ICIP)*, Phoenix, AZ, USA, pp. 111-115, 2016.
- [49] A. F. Z. Yahiaoui and A. Bessaïd, "Segmentation of ischemic stroke area from CT brain images," in *2016 International Symposium on Signal, Image, Video and Communications (ISIVC)*, Tunis, Tunisia, pp. 13-17, 2017.
- [50] C. Zhang, X. Guo, X. Guo, D. Molony, H. Li et al., "Machine learning model comparison for automatic segmentation of intracoronary optical coherence tomography and plaque cap thickness quantification," *CMES-Computer Modeling in Engineering & Sciences*, vol. 123, no. 2, pp. 631–646, 2020.
- [51] K. A. Cauley, G. J. Mongelluzzo and S. W. Fielden, "Automated estimation of acute infarct volume from noncontrast head CT using image intensity inhomogeneity correction," *International Journal of Biomedical Imaging*, vol. 2019, pp. 1-8, 2019.
- [52] G. Litjens, T. Kooi, B. E. Bejnordi, A. A. A. Setio, F. Ciompi et al., "A survey on deep learning in medical image analysis," *Medical Image Analysis*, vol. 42, pp. 60-88, 2017.
- [53] G. Kaur and J. Chhaterji, "A Survey on Medical Image Segmentation," *International Journal of Science and Research*, vol. 6, no. 4, pp. 1305-1311, 2017.
- [54] H. R. Roth, C. Shen, H. Oda, M. Oda, Y. Hayashi et al., "Deep learning and its application to medical image segmentation," *Medical Imaging Technology*, vol. 36, no. 2, pp. 63-71, 2018.
- [55] C. Lo, P. Hung and K. Hsieh, "Computer-aided detection of hyperacute stroke based on relative radiomic patterns in computed tomography," *Applied Sciences*, vol. 9, no. 8, p. 1668, 2019.

- [56] Y. Shinohara, N. Takahashi, Y. Lee, T. Ohmura and T. Kinoshita, “Development of a deep learning model to identify hyperdense MCA sign in patients with acute ischemic stroke,” *Japanese Journal of Radiology*, vol. 38, no. 2, pp. 112-117, 2020.
- [57] F. Chollet, “Xception: Deep learning with depthwise separable convolutions,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, HI, USA, pp. 1251-1258, 2017.
- [58] T. D. Phong, H. N. Duong, H. T. Nguyen, N. T. Trong, V. H. Nguyen *et al.*, “Brain hemorrhage diagnosis by using deep learning,” in *Proceedings of the 2017 International Conference on Machine Learning and Soft Computing*, Ho Chi Minh City, Vietnam, pp. 34-39, 2017.
- [59] C. Lo, P. Hung and D. Lin, “Rapid assessment of acute ischemic stroke by computed tomography using deep convolutional neural networks,” *Journal of Digital Imaging*, vol. 34, no. 3, pp. 637-646, 2021.
- [60] C. M. J. M. Dourado Jr., S. P. P. da Silva, R. V. M. da Nóbrega, A. C. da S. Barros, P. P. R. Filho *et al.*, “Deep learning IoT system for online stroke detection in skull computed tomography images,” *Computer Networks*, vol. 152, pp. 25–39, 2019.
- [61] Y. Xu, G. Holanda, L. F. de F. Souza, H. Silva, A. Gomes *et al.*, “Deep learning-enhanced Internet of medical things to analyze brain CT scans of hemorrhagic stroke patients: A new approach,” *IEEE Sensors Journal*, vol. 21, no. 22, pp. 24941-24951, 2020.
- [62] M. Hu, “Visual pattern recognition by moment invariants,” *IRE Transactions on Information Theory*, vol. 8, no. 2, pp. 179-187, 1962.
- [63] A. Subudhi, M. Dash and S. Sabut, “Automated segmentation and classification of brain stroke using expectation–maximization and random forest classifier,” *Biocybernetics and Biomedical Engineering*, vol. 40, no. 1, pp. 277–289, 2020.
- [64] R. Ortiz-Ramón, M. D. C. V. Hernández, V. González-Castro, S. Makin, P. A. Armitage *et al.*, “Identification of the presence of ischaemic stroke lesions by means of texture analysis on brain magnetic resonance images,” *Computerized Medical Imaging and Graphics*, vol. 74, pp. 12–24, 2019.
- [65] J. J. Titano, M. Badgeley, J. Schefflein, M. Pain, A. Su *et al.*, “Automated deep-neural-network surveillance of cranial images for acute neurologic events,” *Nature medicine*, vol. 24, no. 9, pp. 1337-1341, 2018.
- [66] C. Chin, B. Lin, G. Wu, T. Weng, C. Yang *et al.*, “An automated early ischemic stroke detection system using CNN deep learning algorithm,” in *2017 IEEE 8th International Conference on Awareness Science and Technology (iCAST)*, Taichung, Taiwan, pp. 368–372, 2017.
- [67] T. Han, V. X. Nunes, L. F. D. F. Souza, A. G. Marques, I. C. L. Silva *et al.*, “Internet of medical things – Based on deep learning techniques for segmentation of lung and stroke regions in CT scans,” *IEEE Access*, vol. 8, pp. 71117–71135, 2020.
- [68] F. F. X. Vasconcelos, R. M. Sarmento, P. P. R. Filho and V. H. C. de Albuquerque, “Artificial intelligence techniques empowered edge-cloud architecture for brain CT image analysis,” *Engineering Applications of Artificial Intelligence*, vol. 91, pp. 103585, 2020.

- [69] L. F. Souza, G. Holanda, F. H. Silva, S. S. Alves and P. P. Filho, "Automatic lung segmentation in CT images using mask R-CNN for mapping the feature extraction in supervised methods of machine learning using transfer learning," *International Journal of Hybrid Intelligent Systems*, vol. 16, no. 4, pp. 189-205, 2020.
- [70] Y. Xu, L. F. F. Souza, I. C. L. Silva, A. G. Marques, F. H. S. Silva *et al.*, "A soft computing automatic based in deep learning with use of fine-tuning for pulmonary segmentation in computed tomography images," *Applied Soft Computing*, vol. 112, pp. 107810, 2021.
- [71] N. Tajbakhsh, J. Y. Shin, S. R. Gurudu, R. T. Hurst, C. B. Kendall *et al.*, "Convolutional neural networks for medical image analysis: Full training or fine tuning?," *IEEE Transactions on Medical Imaging*, vol. 35, no. 5, pp. 1299–1312, 2016.
- [72] R. Zhang, L. Zhao, W. Lou, J. M. Abrigo, V. C. T. Mok *et al.*, "Automatic segmentation of acute ischemic stroke from DWI using 3-D fully convolutional DenseNets," *IEEE Transactions on Medical Imaging*, vol. 37, no. 9, pp. 2149-2160, 2018.
- [73] Yeo, M., Tahayori, B., Kok, H. K., Maingard, J., Kutaiba, N., Russell, J., ... & Asadi, H. (2021). Review of deep learning algorithms for the automatic detection of intracranial hemorrhages on computed tomography head imaging. *Journal of neurointerventional surgery*, 13(4), 369-378.
- [74] Salleh, N. S. M., Suliman, A., & Ahmad, A. R. (2011, November). Parallel execution of distributed SVM using MPI (CoDLib). In ICIMU 2011: Proceedings of the 5th international Conference on Information Technology & Multimedia (pp. 1-4). IEEE.
- [75] Al Rub, S. A., Alaiad, A., Hmeidi, I., Quwaider, M., & Alzoubi, O. (2023). Hydrocephalus classification in brain computed tomography medical images using deep learning. *Simulation Modelling Practice and Theory*, 123, 102705.
- [76] Chavva, I. R., Crawford, A. L., Mazurek, M. H., Yuen, M. M., Prabhat, A. M., Payabvash, S., ... & Sheth, K. N. (2022). Deep learning applications for acute stroke management. *Annals of Neurology*, 92(4), 574-587.
- [77] Neethi, A. S., Niyas, S., Kannath, S. K., Mathew, J., Anzar, A. M., & Rajan, J. (2022). Stroke classification from computed tomography scans using 3d convolutional neural network. *Biomedical Signal Processing and Control*, 76, 103720.
- [78] Al-Mekhlafi, Z. G., Senan, E. M., Rassem, T. H., Mohammed, B. A., Makbol, N. M., Alanazi, A. A., ... & Ghaleb, F. A. (2022). Deep learning and machine learning for early detection of stroke and haemorrhage. *Computers, Materials and Continua*, 72(1), 775-796.
- [79] Manickam, P., Mariappan, S. A., Murugesan, S. M., Hansda, S., Kaushik, A., Shinde, R., & Thipperudraswamy, S. P. (2022). Artificial intelligence (AI) and internet of medical things (IoMT) assisted biomedical systems for intelligent healthcare. *Biosensors*, 12(8), 562.

- [80] A. Altayeva, B. Omarov, H.C. Jeong and Y.I. Cho, "Multi-step face recognition for improving face detection and recognition rate", *Far East Journal of Electronics and Communications*, vol. 16, no. 3, pp. 471-491, 2016.
- [81] Woźniak, M., Siłka, J., & Wieczorek, M. (2021). Deep neural network correlation learning mechanism for CT brain tumor detection. *Neural Computing and Applications*, 1-16.
- [82] Qiu, W., Kuang, H., Ospel, J. M., Hill, M. D., Demchuk, A. M., Goyal, M., & Menon, B. K. (2021). Automated prediction of ischemic brain tissue fate from multiphase computed tomographic angiography in patients with acute ischemic stroke using machine learning. *Journal of stroke*, 23(2), 234-243.
- [83] Lin, S. Y., Chiang, P. L., Chen, M. H., Lee, M. Y., Lin, W. C., & Chen, Y. S. (2023). DGA3-Net: A parameter-efficient deep learning model for ASPECTS assessment for acute ischemic stroke using non-contrast computed tomography. *NeuroImage: Clinical*, 38, 103441.
- [84] Mouli, D. V. C. (2023, March). Artificial Intelligence Enabled Framework for Automatic Brain Stroke Detection. In 2023 10th International Conference on Signal Processing and Integrated Networks (SPIN) (pp. 659-664). IEEE.
- [85] Foroushani, H. M., Hamzehloo, A., Kumar, A., Chen, Y., Heitsch, L., Slowik, A & Dhar, R. (2022). Accelerating prediction of malignant cerebral edema after ischemic stroke with automated image analysis and explainable neural networks. *Neurocritical Care*, 36(2), 471-482.
- [86] Saxena, S., Jena, B., Mohapatra, B., Gupta, N., Kalra, M., Scartozzi, M., ... & Suri, J. S. (2023). Fused deep learning paradigm for the prediction of o6-methylguanine-DNA methyltransferase genotype in glioblastoma patients: A neuro-oncological investigation. *Computers in Biology and Medicine*, 153, 106492.
- [87] E. J. Lee, Y. H. Kim, N. Kim and D. W. Kang, “ Deep into the brain: artificial intelligence in stroke imaging,” *Journal of stroke*, vol. 19, pp. 277, 2017
- [88] U. Raghavendra, U. R. Acharya and H. Adeli, “Artificial Intelligence techniques for automated diagnosis of neurological disorders,” *European neurology*, pp. 1-24, 2019
- [89] R. Brouns and P. P. De Deyn, “The complexity of neurobiological processes in acute ischemic stroke,” *Clinical neurology and neurosurgery*, vol. 111, pp. 483-495, 2009
- [90] A. K. Saenger and R. H. Christenson, “Stroke biomarkers: progress and challenges for diagnosis, prognosis, differentiation, and treatment,” *Clinical chemistry*, vol. 56, pp. 21-33, 2010
- [91] F. D. Testai and V. Aiyagari, “Acute hemorrhagic stroke pathophysiology and medical interventions: blood pressure control, management of anticoagulant-associated brain hemorrhage and general management principles,” *Neurologic clinics*, vol. 26, pp. 963-985, 2008
- [92] G. Xi, R. F. Keep and J. T. Hoff, “Mechanisms of brain injury after intracerebral haemorrhage,” *The Lancet Neurology*, vol. 5, pp. 53-63, 2006

- [93] B. Rohaut, K. W. Doyle, A. S. Reynolds, K. Igwe, C. Couch, A. Matory, et al., “Deep structural brain lesions associated with consciousness impairment early after hemorrhagic stroke,” *Scientific reports*, vol. 9, pp. 1-9, 2019
- [94] X. Li, H. Liu, W. Zeng, X. Liu, Y. Wen, Q. Xiong, et al., “The value of whole-brain perfusion parameters combined with multiphase computed tomography angiography in predicting hemorrhagic transformation in ischemic stroke,” *Journal of Stroke and Cerebrovascular Diseases*, vol. 29, pp. 104690, 2020
- [95] A. D. Schweitzer, S. N. Niogi, C. T. Whitlow and A. J. Tsiouris, “Traumatic brain injury: imaging patterns and complications,” *RadioGraphics*, vol. 39, pp. 1571-1595, 2019
- [96] J. F. Scheitz, C. H. Nolte, W. Doebecker, V. Hachinski and M. Endres, “Stroke-heart syndrome: clinical presentation and underlying mechanisms,” *The Lancet Neurology*, vol. 17, pp. 1109-1120, 2018
- [97] J. Fernandez-Mendoza, F. He, A. N. Vgontzas, D. Liao and E. O. Bixler, “Interplay of objective sleep duration and cardiovascular and cerebrovascular diseases on cause-specific mortality,” *Journal of the American Heart Association*, vol. 8, pp. e013043, 2019
- [98] K. Kurisu and M. A. Yenari, “Therapeutic hypothermia for ischemic stroke; pathophysiology and future promise,” *Neuropharmacology*, vol. 134, pp. 302-309, 2018
- [99] Y. Shinya, S. Miyawaki, I. Kumagai, T. Sugiyama, A. Takenobu, N. Saito, et al., “Risk factors and outcomes of cerebral stroke in end-stage renal disease patients receiving hemodialysis,” *Journal of Stroke and Cerebrovascular Diseases*, vol. 29, pp. 104657, 2020
- [100] M. Subramaniyam, D. Singh, S. J. Park, S. E. Kim, D. J. Kim, J. N. Im, et al., “IoT based wake-up stroke prediction-recent trends and directions,” *In IOP Conference Series: Materials Science and Engineering*, vol. 402, pp. 012045, 2018
- [101] P. A. Noseworthy, E. S. Kaufman, L. Y. Chen, M. K. Chung, S. V. E. Mitchell, A. J. José, et al., “Subclinical and device-detected atrial fibrillation: pondering the knowledge gap: a scientific statement from the american heart association,” *Circulation*, vol. 140, pp. e944–e963, 2019
- [102] M. N. K. Boulos and G. Haywood, “Opportunistic atrial fibrillation screening and detection in “self-service health check-up stations”: A brief overview of current technology potential and possibilities,” *mHealth*, vol. 7, 2021
- [103] R. Mahajan, T. Perera, A. D. Elliott, D. J. Twomey, S. Kumar, D. A. Munwar, et al., “Subclinical device-detected atrial fibrillation and stroke risk: A systematic review and meta-analysis,” *Eur. Heart J.*, vol. 39, pp. 1407–1415, 2018
- [104] T. Periyaswamy and M. Balasubramanian, “Ambulatory cardiac bio-signals: From mirage to clinical reality through a decade of progress,” *Int. J. Med.*, vol. 130, 2019
- [105] L. García, J. Tomás, L. Parra and J. Lloret, “An m-health application for cerebral stroke detection and monitoring using cloud services,” *International Journal of Information Management*, vol. 45, pp. 319-327, 2019

- [106] N. M. AbdElnapi, N. F. Omran, A. A. Ali and F. A. Omara, “A framework for stroke prevention using IoT healthcare sensors. In *Internet of Things—Applications and Future: Proceedings of ITAF 2019*, Springer Singapore, pp. 175–186, 2019
- [107] J. E. S. Kenny, C. E. Munding, J. K. Eibl, A. M. Eibl, B. F. Long, A. Boyes, et al., “A novel, hands-free ultrasound patch for continuous monitoring of quantitative Doppler in the carotid artery,” *Scientific Reports*, vol. 11, pp. 7780, 2021
- [108] Yoav Freund and Robert E. Schapire. 1996. Experiments with a new boosting algorithm. In Proceedings ofS. Sanda, T. Hara, Q. Li, R. Tanaka, N. Niki, G. N. Lee, H. Fujita, J. You, H. Arimura, T. Katafuchi, et al., “State-of-the-art of computeraided detection/diagnosis,” 2010. the Thirteenth International Conference on Machine Learning, pages 148–156.
- [109] J. J. Fenton, S. H. Taplin, P. A. Carney, L. Abraham, E. A. Sickles, C. D’Orsi, E. A. Berns, G. Cutter, R. E. Hendrick, W. E. Barlow, et al., “Influence of computer-aided detection on performance of screening mammography,” *New England Journal of Medicine*, vol. 356, no. 14, pp. 1399–1409, 2007.
- [110] Huang, H. K. (2014). Medical imaging, PACS, and imaging informatics: retrospective. *Radiological physics and technology*, 7(1), 5-24.
- [111] H. Fujita, Y. Uchiyama, T. Nakagawa, D. Fukuoka, Y. Hatanaka, T. Hara, G. N. Lee, Y. Hayashi, Y. Ikeda, X. Gao, et al., “Computeraided diagnosis: The emerging of three cad systems induced by japanese health care needs,” *Computer methods and programs in biomedicine*, vol. 92, no. 3, pp. 238–248, 2008.
- [112] N. M. Saad, S. Bakar, A. S. Muda, and M. M. Mokji, “Review of brain lesion detection and classification using neuroimaging analysis techniques,” *Jurnal Teknologi*, vol. 74, no. 6, pp. 73–85, 2015.
- [113] E.-S. A. El-Dahshan, H. M. Mohsen, K. Revett, and A.-B. M. Salem, “Computer-aided diagnosis of human brain tumor through mri: A survey and a new algorithm,” *Expert systems with Applications*, vol. 41, no. 11, pp. 5526–5545, 2014.
- [114] J. A. Ludwig and J. N. Weinstein, “Biomarkers in cancer staging, prognosis and treatment selection,” *Nature Reviews Cancer*, vol. 5, no. 11, p. 845, 2005
- [115] T. Inoue, T. Nakaura, M. Yoshida, K. Yokoyama, K. Hirata, M. Kidoh, S. Oda, D. Utsunomiya, K. Harada, and Y. Yamashita, “Diagnosis of small posterior fossa stroke on brain ct: effect of iterative reconstruction designed for brain ct on detection performance,” *European radiology*, vol. 27, no. 9, pp. 3710–3715, 2017
- [116] Y. Iyama, T. Nakaura, S. Oda, M. Kidoh, D. Utsunomiya, M. Yoshida, H. Yuki, K. Hirata, Y. Funama, K. Harada, et al., “Iterative reconstruction designed for brain ct: A correlative study with filtered back projection for the diagnosis of acute ischemic stroke,” *Journal of Computer Assisted Tomography*, vol. 41, no. 6, pp. 884–890, 2017
- [117] R. Gomolka, R. Chrzan, A. Urbanik, R. Kazmierski, A. Grzanka, and W. Nowinski, “Quantification of image contrast of infarcts on computed tomography scans,” *The neuroradiology journal*, vol. 30, no. 1, pp. 15–22, 2017
- [118] D. R. Pereira, P. P. Reboucas Filho, G. H. de Rosa, J. P. Papa, and V. H. C. de Albuquerque, “Stroke lesion detection using convolutional neural networks,” in *2018 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2018, pp. 1–6.

- [119] K. Sudharani, T. Sarma, and K. S. Prasad, "Brain stroke detection using k-nearest neighbor and minimum mean distance technique," in Control, Instrumentation, Communication and Computational Technologies (ICCICCT), 2015 International Conference on. IEEE, 2015, pp. 770–776
- [120] D. Guo, J. Fridriksson, P. Fillmore, C. Rorden, H. Yu, K. Zheng, and S. Wang, "Automated lesion detection on mri scans using combined unsupervised and supervised methods," *BMC medical imaging*, vol. 15, 2015
- [121] Dourado Jr, C. M., da Silva, S. P. P., da Nóbrega, R. V. M., Barros, A. C. D. S., Reboucas Filho, P. P., & de Albuquerque, V. H. C. (2019). Deep learning IoT system for online stroke detection in skull computed tomography images. *Computer Networks*, 152, 25-39.
- [122] Songram, P., & Jareanpon, C. (2019, November). A Study of Features Affecting on Stroke Prediction Using Machine Learning. In *International Conference on Multi-disciplinary Trends in Artificial Intelligence* (pp. 216-225). Springer, Cham.
- [123] Li, X., Bian, D., Yu, J., Li, M., & Zhao, D. (2019). Using machine learning models to improve stroke risk level classification methods of China national stroke screening. *BMC Medical Informatics and Decision Making*, 19(1), 261.
- [124] Heros, R. C. (1994). Stroke: early pathophysiology and treatment. Summary of the Fifth Annual Decade of the Brain Symposium. *Stroke*, 25(9), 1877-1881.
- [125] Karadima, O., Rahman, M., Sotiriou, I., Ghavami, N., Lu, P., Ahsan, S., & Kosmas, P. (2020). Experimental Validation of Microwave Tomography with the DBIM-TwIST Algorithm for Brain Stroke Detection and Classification. *Sensors*, 20(3), 840.
- [126] Shao, Y. H., Tsai, K., Kim, S., Wu, Y. J., & Demissie, K. (2020). Exposure to Tomographic Scans and Cancer Risks. *JNCI Cancer Spectrum*, 4(1), pkz072.
- [127] Chandra, R., Zhou, H., Balasingham, I., & Narayanan, R. M. (2015). On the opportunities and challenges in microwave medical sensing and imaging. *IEEE transactions on biomedical engineering*, 62(7), 1667-1682.
- [128] Tobon Vasquez, J. A., Scapaticci, R., Turvani, G., Bellizzi, G., Joachimowicz, N., Duchêne, B., ... & Vipiana, F. (2019). Design and Experimental Assessment of a 2D Microwave Imaging System for Brain Stroke Monitoring. *International Journal of Antennas and Propagation*, 2019.
- [129] Mobashsher, A. T., Bialkowski, K. S., Abbosh, A. M., & Crozier, S. (2016). Design and experimental evaluation of a non-invasive microwave head imaging system for intracranial haemorrhage detection. *Plos one*, 11(4).
- [130] Merunka, I., Massa, A., Vrba, D., Fiser, O., Salucci, M., & Vrba, J. (2019). Microwave tomography system for methodical testing of human brain stroke detection approaches. *International Journal of Antennas and Propagation*, 2019.
- [131] Persson, M., Fhager, A., Trefná, H. D., Yu, Y., McKelvey, T., Pegenius, G., ... & Elam, M. (2014). Microwave-based stroke diagnosis making global prehospital thrombolytic treatment possible. *IEEE Transactions on Biomedical Engineering*, 61(11), 2806-2817.
- [132] Karadima, O., Rahman, M., Sotiriou, I., Ghavami, N., Lu, P., Ahsan, S., & Kosmas, P. (2020). Experimental Validation of Microwave Tomography with the

- DBIM-TwIST Algorithm for Brain Stroke Detection and Classification. *Sensors*, 20(3), 840.
- [133] Hopfer, M., Planas, R., Hamidipour, A., Henriksson, T., & Semenov, S. (2017). Electromagnetic Tomography for Detection, Differentiation, and Monitoring of Brain Stroke: A Virtual Data and Human Head Phantom Study. *IEEE Antennas and Propagation Magazine*, 59(5), 86-97.
- [134] Scapaticci, R., Di Donato, L., Catapano, I., & Crocco, L. (2012). A feasibility study on microwave imaging for brain stroke monitoring. *Progress In Electromagnetics Research*, 40, 305-324.
- [135] Scapaticci, R., Tobon, J., Bellizzi, G., Vipiana, F., & Crocco, L. (2018). Design and numerical characterization of a low-complexity microwave device for brain stroke monitoring. *IEEE Transactions on Antennas and Propagation*, 66(12), 7328-7338.
- [136] Haddad, W. S., & Trebes, J. E. (2007). U.S. Patent No. 7,226,415. Washington, DC: U.S. Patent and Trademark Office.
- [137] Persson, M., Fhager, A., Trefná, H. D., Yu, Y., McKelvey, T., Pegenius, G., ... & Elam, M. (2014). Microwave-based stroke diagnosis making global prehospital thrombolytic treatment possible. *IEEE Transactions on Biomedical Engineering*, 61(11), 2806-2817.
- [138] Hopfer, M., Planas, R., Hamidipour, A., Henriksson, T., & Semenov, S. (2017). Electromagnetic Tomography for Detection, Differentiation, and Monitoring of Brain Stroke: A Virtual Data and Human Head Phantom Study. *IEEE Antennas and Propagation Magazine*, 59(5), 86-97.
- [139] Scapaticci, R., Di Donato, L., Catapano, I., & Crocco, L. (2012). A feasibility study on microwave imaging for brain stroke monitoring. *Progress In Electromagnetics Research*, 40, 305-324.
- [140] Cardoso, M. J., Sudre, C. H., Modat, M., & Ourselin, S. (2015, June). Template-based multimodal joint generative model of brain data. In International Conference on Information Processing in Medical Imaging (pp. 17-29). Springer, Cham.
- [141] M. Erihov, S. Alpert, P. Kisilev, S. Hashoul A cross saliency approach to asymmetry-based tumor detection Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI) (2015), pp. 636-643
- [142] B. de Haan, P. Clas, H. Juenger, M. Wilke, and H.-O. Karnath, “Fast semi-automated lesion demarcation in stroke,” *NeuroImage: Clinical*, vol. 9, pp. 69–74, 2015.
- [143] E. Hajimani, M. Ruano, and A. Ruano, “Moga design for neural networks based system for automatic diagnosis of cerebral vascular accidents,” in Intelligent Signal Processing (WISP), 2015 IEEE 9th International Symposium on. IEEE, 2015, pp. 1–6.
- [144] M. Ruano, E. Hajimani, and A. Ruano, “A radial basis function classifier for the automatic diagnosis of cerebral vascular accidents,” in Global Medical

- Engineering Physics Exchanges/Pan American Health Care Exchanges (GMEPE/PAHCE), 2016. IEEE, 2016, pp. 1–4.
- [145] Nazari-Farsani, S., Nyman, M., Karjalainen, T., Bucci, M., Isojärvi, J., & Nummenmaa, L. (2020). Automated Segmentation of Acute Stroke Lesions Using a Data-driven Anomaly Detection on Diffusion Weighted MRI. *Journal of Neuroscience Methods*, 108575.
- [146] F. Aghaei, S. R. Ross, Y. Wang, D. H. Wu, B. O. Cornwell, B. Ray, and B. Zheng, “Implementation of a computer-aided detection tool for quantification of intracranial radiologic markers on brain ct images,” in SPIE Medical Imaging. International Society for Optics and Photonics, 2017, pp. 1 013 805–1 013 805
- [147] Xue, Y., Farhat, F. G., Boukrina, O., Barrett, A. M., Binder, J. R., Roshan, U. W., & Graves, W. W. (2020). A multi-path 2.5 dimensional convolutional neural network system for segmenting stroke lesions in brain MRI images. *NeuroImage: Clinical*, 25, 102118.
- [148] N. Bhadauria, M. Bist, R. Patel, and H. Bhadauria, “Performance evaluation of segmentation methods for brain ct images based hemorrhage detection,” in Computing for Sustainable Global Development (INDIACoM), 2015 2nd International Conference on. IEEE, 2015, pp. 1955–1959
- [149] M. Sun, R. Hu, H. Yu, B. Zhao, and H. Ren, “Intracranial hemorrhage detection by 3d voxel segmentation on brain ct images,” in Wireless Communications & Signal Processing (WCSP), 2015 International Conference on. IEEE, 2015, pp. 1–5
- [150] Qiu, W., Kuang, H., Teleg, E., Ospel, J. M., Sohn, S. I., Almekhlafi, M., ... & Menon, B. K. (2020). Machine Learning for Detecting Early Infarction in Acute Stroke with Non-Contrast-enhanced CT. *Radiology*, 294(3), 638-644.
- [151] E. d. S. Reboucas, A. M. Braga, R. M. Sarmento, R. C. Marques, and P. P. Reboucas Filho, “Level set based on brain radiological densities for stroke segmentation in ct images,” in 2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS). IEEE, 2017, pp. 391–396
- [152] A. F. Z. Yahiaoui and A. Bessaïd, “Segmentation of ischemic stroke area from ct brain images,” in Signal, Image, Video and Communications (ISIVC), International Symposium on. IEEE, 2016, pp. 13–17
- [153] ISLES 2018 dataset <http://www.isles-challenge.org/>
- [154] O. Maier, B. H. Menze, J. von der Gabeltz, L. Hani, M. P. Heinrich, " M. Liebrand, S. Winzeck, A. Basit, P. Bentley, L. Chen, et al., “Isles 2015-a public evaluation benchmark for ischemic stroke lesion segmentation from multispectral mri,” *Medical image analysis*, vol. 35, pp. 250–269, 2017
- [155] Chen L, Bentley P, Rueckert D. Fully automatic acute ischemic lesion segmentation in DWI using convolutional neural networks. *NeuroImage Clin.* 2017;15:633– 643.
- [156] Boldsen JK, Engedal TS, Pedraza S, et al. Better diffusion segmentation in acute ischemic stroke through automatic tree learning anomaly segmentation. *Front Neuroinform.* 2018;12:21.

- [157] Valdes-Sosa PA, Popa-Wagner A, Llibre-Guerra JJ, et al. Better diffusion segmentation in acute ischemic stroke through automatic tree learning anomaly segmentation. *Front Neuroinform*. 2015;12. DOI:10.3389/fninf.2018.00021.
- [158] Nagel S, Sinha D, Day D, et al. e-ASPECTS software is non-inferior to neuroradiologists in applying the ASPECT score to computed tomography scans of acute ischemic stroke patients. *Int J Stroke*. 2017;12:615–622.
- [159] Chen L, Carlton Jones AL, Mair G, et al. Rapid automated quantification of cerebral leukoaraiosis on CT images: a multicenter validation study. *Radiology*. 2018;171567. DOI:10.1148/radiol.2018171567.
- [160] Takahashi N, Lee Y, Tsai D-Y, et al. An automated detection method for the MCA dot sign of acute stroke in unenhanced CT. *Radiol Phys Technol*. 2014;7:79–88.
- [161] Kamnitsas, K., Ledig, C., Newcombe, V. F., Simpson, J. P., Kane, A. D., Menon, D. K., ... & Glocker, B. (2017). Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. *Medical image analysis*, 36, 61-78.
- [162] Maier, O., Menze, B. H., von der Gabeltz, J., Häni, L., Heinrich, M. P., Liebrand, M., ... & Christiaens, D. (2017). ISLES 2015-A public evaluation benchmark for ischemic stroke lesion segmentation from multispectral MRI. *Medical image analysis*, 35, 250-269.
- [163] <https://www.ersplus.ru/stati/uzi/printsip-doplera> дата обращения 02.05.2024
- [164] Pustina, D., Coslett, H. B., Turkeltaub, P. E., Tustison, N., Schwartz, M. F., & Avants, B. (2016). Automated segmentation of chronic stroke lesions using LINDA: Lesion identification with neighborhood data analysis. *Human brain mapping*, 37(4), 1405-1421.
- [165] Omarov B., Tursynova A., Uzak M. Deep Learning Enhanced Internet of Medical Things to Analyze Brain Computed Tomography Images of Stroke Patients //International Journal of Advanced Computer Science and Applications. – 2023. – Т. 14. – №. 8.
- [166] Chen, L., Bentley, P., & Rueckert, D. (2017). Fully automatic acute ischemic lesion segmentation in DWI using convolutional neural networks. *NeuroImage: Clinical*, 15, 633-643.
- [167] Tursynova A. et al. Deep learning-enabled brain stroke classification on computed tomography images //Computers, Materials & Continua. – 2023. – Т. 75. – №. 1. – С. 1431-1446.
- [168] Omarov B. et al. Modified UNet Model for Brain Stroke Lesion Segmentation on Computed Tomography Images //Computers, Materials & Continua. – 2022. – Т. 71. – №. 3.
- [169] Tursynova, A., Omarov, B., Sakhipov, A., Tukenova, N. Brain Stroke Lesion Segmentation Using Computed Tomography Images based on Modified U-Net Model with ResNet Blocks //International Journal of Online & Biomedical Engineering. – 2022. – Т. 18. – №. 13.

- [170] Tursynova A., Omarov B. 3D U-Net for brain stroke lesion segmentation on ISLES 2018 dataset //2021 16th International Conference on Electronics Computer and Computation (ICECCO). – IEEE, 2021. – C. 1-4.
- [171] Prevedello, L. M., Erdal, B. S., Ryu, J. L., Little, K. J., Demirer, M., Qian, S., & White, R. D. (2017). Automated critical test findings identification and online notification system using artificial intelligence in imaging. *Radiology*, 285(3), 923-931.
- [172] Chen, Y., Dhar, R., Heitsch, L., Ford, A., Fernandez-Cadenas, I., Carrera, C., ... & Lee, J. M. (2016). Automated quantification of cerebral edema following hemispheric infarction: application of a machine-learning algorithm to evaluate CSF shifts on serial head CTs. *NeuroImage: Clinical*, 12, 673-680.
- [173] Abedi, V., Goyal, N., Tsivgoulis, G., Hosseinichimeh, N., Hontecillas, R., Bassaganya-Riera, J., ... & Alexandrov, A. V. (2017). Novel screening tool for stroke using artificial neural network. *Stroke*, 48(6), 1678-1681.
- [174] Bharathi, P. G., Agrawal, A., Sundaram, P., & Sardesai, S. (2019). Combination of hand-crafted and unsupervised learned features for ischemic stroke lesion detection from Magnetic Resonance Images. *Biocybernetics and Biomedical Engineering*, 39(2), 410-425.
- [175] Hajimani, E., Ruano, M. G., & Ruano, A. E. (2017). An intelligent support system for automatic detection of cerebral vascular accidents from brain CT images. *Computer methods and programs in biomedicine*, 146, 109-123.
- [176] Nichols, T. E., Das, S., Eickhoff, S. B., Evans, A. C., Glatard, T., Hanke, M., ... & Proal, E. (2017). Best practices in data analysis and sharing in neuroimaging using MRI. *Nature neuroscience*, 20(3), 299-303.
- [177] Jadhav, A. P., Desai, S. M., Liebeskind, D. S., & Wechsler, L. R. (2020). Neuroimaging of Acute Stroke. *Neurologic clinics*, 38(1), 185-199.
- [178] Coughlin, J. M., Horti, A. G., & Pomper, M. G. (2019). Opportunities in precision psychiatry using PET neuroimaging in psychosis. *Neurobiology of disease*.
- [179] Tursynova, A., Omarov, B., Shuketayeva, K., Smagul, M. Artificial Intelligence in Stroke Imaging //2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence). – IEEE, 2021. – C. 41-45.
- [180] P. P. Reboucas Filho, R. M. Sarmento, G. B. Holanda, and D. de Alencar Lima, “New approach to detect and classify stroke in skull ct images via analysis of brain tissue densities,” *Computer Methods and Programs in Biomedicine*, vol. 148, pp. 27–43, 2017.
- [181] P. P. Reboucas Filho, E. d. S. Reboucas, L. B. Marinho, R. M. Sarmento, J. M. R. Tavares, and V. H. C. de Albuquerque, “Analysis of human tissue densities: A new approach to extract features from medical images,” *Pattern Recognition Letters*, 2017.
- [182] R. Jeena and S. Kumar, “Analysis of stroke using texture features,” in *Control Communication & Computing India (ICCC)*, 2015 International Conference on. IEEE, 2015, pp. 366–370.
- [183] G. Ostrek, A. Nowakowski, M. Jasionowska, A. Przelaskowski, and K. Szopiński, “Stroke tissue pattern recognition based on ct texture analysis,” in

- Proceedings of the 9th International Conference on Computer Recognition Systems CORES 2015. Springer, 2016, pp. 81–90.
- [184] Dourado Jr, C. M., da Silva, S. P. P., da Nóbrega, R. V. M., Barros, A. C. D. S., Reboucas Filho, P. P., & de Albuquerque, V. H. C. (2019). Deep learning IoT system for online stroke detection in skull computed tomography images. *Computer Networks*, 152, 25-39.
- [185] Saba, L., Jain, P. K., Suri, H. S., Ikeda, N., Araki, T., Singh, B. K., ... & Suri, J. S. (2017). Plaque tissue morphology-based stroke risk stratification using carotid ultrasound: a polling-based PCA learning paradigm. *Journal of medical systems*, 41(6), 98.
- [186] Acharya UR, Faust O, Sree SV, et al. An accurate and generalized approach to plaque characterization in 346 carotid ultrasound scans. *IEEE Trans Instrum Meas*. 2012;61(4):1045–53 This was an important study that performed the carotid atherosclerotic plaque characterization using ML approach.
- [187] Yeo, L. L., Tu, T. M., Selvaraj, V., Monajemi, S., Mohammadzadeh, M., Tan, B., & Sharma, V. (2019). Abstract TP238: Detecting Intraplaque Hemorrhage in Carotid Ultrasound Using Machine Learning. *Stroke*, 50(Suppl\_1), ATP238-ATP238.
- [188] Ikeda, N., Dey, N., Sharma, A., Gupta, A., Bose, S., Acharjee, S., ... & Laird, J. R. (2017). Automated segmental-IMT measurement in thin/thick plaque with bulb presence in carotid ultrasound from multiple scanners: Stroke risk assessment. *Computer methods and programs in biomedicine*, 141, 73-81.
- [189] Saba, L., Banchhor, S. K., Suri, H. S., Londhe, N. D., Araki, T., Ikeda, N., ... & Nicolaides, A. (2016). Accurate cloud-based smart IMT measurement, its validation and stroke risk stratification in carotid ultrasound: a web-based point-of-care tool for multicenter clinical trial. *Computers in biology and medicine*, 75, 217-234.
- [190] Cuadrado-Godia E, Srivastava SK, Saba L, et al: Geometric total plaque area is an equally powerful phenotype compared with carotid intima-media thickness for stroke risk assessment: a deep learning approach. *J Vasc Ultrasound* 2018. 1544316718806421
- [191] Huibers A, de Borst GJ, Bulbulia R, Pan H, Halliday A. Plaque echolucency and the risk of ischaemic stroke in patients with asymptomatic carotid stenosis within the first Asymptomatic Carotid Surgery Trial (ACST-1). *Eur J Vasc Endovasc Surg*. 2016;51(5):616–21
- [192] Kotsis V, Jamthikar AD, Araki T, et al. Echolucency-based phenotype in carotid atherosclerosis disease for risk stratification of diabetes patients. *Diabetes Res Clin Pract*. 2018;143:322–31
- [193] Park TH. Evaluation of carotid plaque using ultrasound imaging. *J Cardiovasc Ultrasound*. 2016;24(2):91–5.
- [194] Picano E, Paterni M. Ultrasound tissue characterization of vulnerable atherosclerotic plaque. *Int J Mol Sci*. 2015;16(5):10121–33
- [195] Nicolaides AN, Kakkos SK, Kyriacou E, et al. Asymptomatic internal carotid artery stenosis and cerebrovascular risk stratification. *J Vasc Surg*. 2010;52(6):1486–1496.e1485

- [196] Donahue, M. J., Dlamini, N., Bhatia, A., & Jordan, L. C. (2019). Neuroimaging advances in pediatric stroke. *Stroke*, 50(2), 240-248.
- [197] Giese, A. K., Schirmer, M. D., Donahue, K. L., Cloonan, L., Irie, R., Winzeck, S., ... & Sridharan, R. (2017). Design and rationale for examining neuroimaging genetics in ischemic stroke: The MRI-GENIE study. *Neurology Genetics*, 3(5), e180.
- [198] Jamthikar, A., Gupta, D., Khanna, N. N., Araki, T., Saba, L., Nicolaides, A., ... & Mavrogeni, S. (2019). A special report on changing trends in preventive stroke/cardiovascular risk assessment via B-mode ultrasonography. *Current atherosclerosis reports*, 21(7), 25.
- [199] Juttukonda, M. R., & Donahue, M. J. (2019). Neuroimaging of vascular reserve in patients with cerebrovascular diseases. *Neuroimage*, 187, 192-208.
- [200] Acharya RU, Faust O, Alvin APC, et al. Symptomatic vs. asymptomatic plaque classification in carotid ultrasound. *J Med Syst*. 2012;36(3):1861–71.
- [201] Acharya UR, Faust O, Alvin A, et al. Understanding symptomatology of atherosclerotic plaque by image-based tissue characterization. *Comput Methods Prog Biomed*. 2013;110(1):66–75
- [202] B. Shahangian and H. Pourghassem, “Automatic brain hemorrhage segmentation and classification algorithm based on weighted grayscale histogram feature in a hierarchical classification structure,” *Biocybernetics and Biomedical Engineering*, vol. 36, no. 1, pp. 217–232, 2016.
- [203] Kuang, H., Menon, B. K., & Qiu, W. (2019). Segmenting hemorrhagic and ischemic infarct simultaneously from follow-up non-contrast CT images in patients with acute ischemic stroke. *IEEE Access*, 7, 39842-39851.
- [204] Narayanan, A., Rajasekaran, M. P., Zhang, Y., Govindaraj, V., & Thiagarajan, A. (2019). Multi-channeled MR brain image segmentation: A novel double optimization approach combined with clustering technique for tumor identification and tissue segmentation. *Biocybernetics and Biomedical Engineering*, 39(2), 350-381.
- [205] Limkin, E. J., Sun, R., Dercle, L., Zacharaki, E. I., Robert, C., Reuzé, S., ... & Ferté, C. (2017). Promises and challenges for the implementation of computational medical imaging (radiomics) in oncology. *Annals of Oncology*, 28(6), 1191-1206.
- [206] A. Subudhi, U. R. Acharya, M. Dash, S. Jena, and S. Sabut, “Automated approach for detection of ischemic stroke using delaunay triangulation in brain mri images,” *Computers in Biology and Medicine*, 2018.
- [207] Sachdeva, J., Kumar, V., Gupta, I., Khandelwal, N., & Ahuja, C. K. (2013). Segmentation, feature extraction, and multiclass brain tumor classification. *Journal of digital imaging*, 26(6), 1141-1150.
- [208] Sachdeva, J., Kumar, V., Gupta, I., Khandelwal, N., & Ahuja, C. K. (2016). A package-SFERCB-“Segmentation, feature extraction, reduction and classification analysis by both SVM and ANN for brain tumors”. *Applied soft computing*, 47, 151-167.
- [209] M. Hopfer, R. Planas, A. Hamidipour, T. Henriksson, and S. Semenov, “Electromagnetic tomography for detection, differentiation, and monitoring of brain

- stroke: A virtual data and human head phantom study." IEEE Antennas and Propagation Magazine, vol. 59, no. 5, pp. 86–97, 2017.
- [210] S. Semenov, M. Hopfer, R. Planas, A. Hamidipour, and T. Henriksson, "Electromagnetic tomography for brain imaging: 3d reconstruction of stroke in a human head phantom," in Antenna Measurements & Applications (CAMA), 2016 IEEE Conference on. IEEE, 2016, pp. 1–4.
- [211] P.-H. Tournier, F. Hecht, F. Nataf, M. Bonazzoli, F. Rapetti, V. Dolean, S. Semenov, I. El Kanfoud, I. Aliferis, C. Migliaccio, et al., "Microwave tomography for brain stroke imaging," in Antennas and Propagation & USNC/URSI National Radio Science Meeting, 2017 IEEE International Symposium on. IEEE, 2017, pp. 29–30.
- [212] For example <http://www.fast.ai>, <https://www.deeplearning.ai>, <http://cs231n.stanford.edu>, <https://developers.google.com/machine-learning/crash-course>.
- [213] Guohun Zhu, "DATASET for "Stroke Classification in Electromagnetic Imaging Using Graph Approaches""", IEEE Dataport, 2019. [Online]. Available: <http://dx.doi.org/10.21227/es43-bf10>. Accessed: Mar. 26, 2020.
- [214] <https://scikit-rf.readthedocs.io/en/latest/index.html?highlight=RF%2FMicrowave%20engineering#>
- [215] <https://github.com/apolanco3225/Data-Augmentation-and-Segmentation-with-GANs-for-Medical-Images>
- [216] <https://github.com/farisfizal/imorrage>
- [217] <https://github.com/jbriscoe1/DeepLearningForStroke>
- [218] <https://github.com/WuChanada/Acute-ischemic-lesion-segmentation-in-NCCT>
- [219] <https://github.com/NIC-VICROB/SUNet-architecture>
- [220] <https://github.com/Andrewsher/X-Net>
- [221] [https://github.com/YH0517/CLCI\\_Net](https://github.com/YH0517/CLCI_Net)
- [222] <https://github.com/CarlosUziel/ischleseg>
- [223] Foroushani, H. M., Dhar, R., Chen, Y., Gurney, J., Hamzehloo, A., Lee, J. M., & Marcus, D. S. (2020, March). SNIPR: Stroke Neuroimaging Phenotype Repository. In *Medical Imaging 2020: Imaging Informatics for Healthcare, Research, and Applications* (Vol. 11318, p. 113180B). International Society for Optics and Photonics
- [224] Hossein Mohammadian Foroushani, Rajat Dhar, Yasheng Chen, Jenny Gurney, Ali Hamzehloo, Jin-Moo Lee, and Daniel S. Marcus "SNIPR: Stroke Neuroimaging Phenotype Repository", Proc. SPIE 11318, Medical Imaging 2020: Imaging Informatics for Healthcare, Research, and Applications, 113180B (2 March 2020); <https://doi.org/10.1117/12.2549622>
- [225] <https://www.icpsr.umich.edu/icpsrweb/ADDEP/studies/36684/versions/V1>
- [226] Liew, S.-L. *et al.* A large, open source dataset of stroke anatomical brain images and manual lesion segmentations. *Sci. Data* 5:180011 doi: 10.1038/sdata.2018.11 (2018).
- [227] Liew, Sook-Lei. The Anatomical Tracings of Lesions after Stroke (ATLAS) Dataset - Release 1.1, 2017. Ann Arbor, MI: Inter-university Consortium for Political

- and Social Research [distributor], 2017-08-24.
- <https://doi.org/10.3886/ICPSR36684.v1>
- [228] <http://ieee-dataport.org/documents/dataset-stroke-classification-electromagnetic-imaging-using-graph-approaches>
- [229] <http://dx.doi.org/10.21227/es43-bf10>
- [230] <http://ieee-dataport.org/1317>
- [231] <https://openneuro.org>
- [232] Goren, N. et al. Multi-frequency electrical impedance tomography and neuroimaging data in stroke patients. *Sci. Data* 5, 180112 (2018)
- [233] Tursynova A. T. et al. Convolutional deep learning neural network for stroke image recognition //Journal of Mathematics, Mechanics and Computer Science. – 2021. – T. 112. – №. 4.
- [234] [https://github.com/EIT-team/Stroke\\_EIT\\_Dataset](https://github.com/EIT-team/Stroke_EIT_Dataset)
- [235] <http://www.ukbiobank.ac.uk/>
- [236] Msayib, Y. (2017). Dataset for 'Quantitative CEST Imaging of Amide Proton Transfer in Acute Stroke'. University of Oxford
- [237] <https://ora.ox.ac.uk/objects/uuid:3b6ba5ea-d607-423a-a34f-e17e0c29183d>
- [238] <https://nhird.nhri.org.tw/en>
- [239] National Health Insurance Administration, Ministry of Health and Welfare, Taiwan, R.O.C. (2014). National Health Insurance Annual Report 2014-2015
- [240] [https://www.kaggle.com/c/rsna-intracranial-hemorrhage-detection/overview?utm\\_medium=email&utm\\_source=intercom&utm\\_campaign=competition-recaps-rsna-2019](https://www.kaggle.com/c/rsna-intracranial-hemorrhage-detection/overview?utm_medium=email&utm_source=intercom&utm_campaign=competition-recaps-rsna-2019)
- [241] <https://projects.iq.harvard.edu/cdmri2018/challenge>
- [242] Nogueira, R. G., Jadhav, A. P., Haussen, D. C., Bonafe, A., Budzik, R. F., Bhuva, P., ... & Sila, C. A. (2018). Thrombectomy 6 to 24 hours after stroke with a mismatch between deficit and infarct. *New England Journal of Medicine*, 378(1), 11-21.
- [243] Berkhemer, OA, Fransen, PS, Beumer, D et al. A randomized trial of intraarterial treatment for acute ischemic stroke. *N Engl J Med*. 2015; 372: 11–20
- [244] Campbell, BC, Mitchell, PJ, Kleinig, TJ et al. Endovascular therapy for ischemic stroke with perfusion-imaging selection. *N Engl J Med*. 2015; 372: 1009–1018
- [245] Goyal, M, Demchuk, AM, Menon, BK et al. Randomized assessment of rapid endovascular treatment of ischemic stroke. *N Engl J Med*. 2015; 372: 1019–1030
- [246] Jovin, TG, Chamorro, A, Cobo, E et al. Thrombectomy within 8 hours after symptom onset in ischemic stroke. *N Engl J Med*. 2015; 372: 2296–2306.
- [247] Kamal, H., Lopez, V., & Sheth, S. A. (2018). Machine learning in acute ischemic stroke neuroimaging. *Frontiers in neurology*, 9, 945.
- [248] Zacharaki, E. I., Wang, S., Chawla, S., Soo Yoo, D., Wolf, R., Melhem, E. R., & Davatzikos, C. (2009). Classification of brain tumor type and grade using MRI texture and shape in a machine learning scheme. *Magnetic Resonance in Medicine: An Official Journal of the International Society for Magnetic Resonance in Medicine*, 62(6), 1609-1618.