

ОТСЛЕЖИВАНИЕ КЛЮЧЕВЫХ ТОЧЕК В АОРТОГРАФИИ С ИСПОЛЬЗОВАНИЕМ РЕКУРРЕНТНЫХ И СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ¹

Русаков К.Д., Гергет О.М.

Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия

rusakov.msk@yandex.ru, gerget@ipu.ru

Аннотация. Предложен метод отслеживания ключевых точек в аортографии с помощью гибридной модели сверточной и рекуррентной нейронной сети, обеспечивающий точность классификации 98% и среднюю ошибку регрессии 4%. Это улучшает позиционирование аортального клапана в процедуре TAVI.

Ключевые слова: отслеживание ключевых точек, транслюминальная имплантация аортального клапана, глубокое обучение, свёрточные нейронные сети, анализ медицинских изображений, аортография, рекуррентные нейронные сети.

Введение

Транслюминальная имплантация аортального клапана (TAVI) является относительно новым и высокоэффективным методом лечения средне и высоко рискованных пациентов с аортальным стенозом. С момента первой процедуры в 2002 году количество операций TAVI неуклонно растет, а показания для проведения данной процедуры продолжают расширяться. Выживаемость пациентов в краткосрочной и долгосрочной перспективе после TAVI сопоставима с выживаемостью после хирургической замены аортального клапана. Минимально инвазивные процедуры связаны с более низкой смертностью и меньшим числом послеоперационных осложнений, таких как атриовентрикулярный блок, требующий немедленного пейсинга, и парапротестические утечки, влияющие на показатели выживаемости.

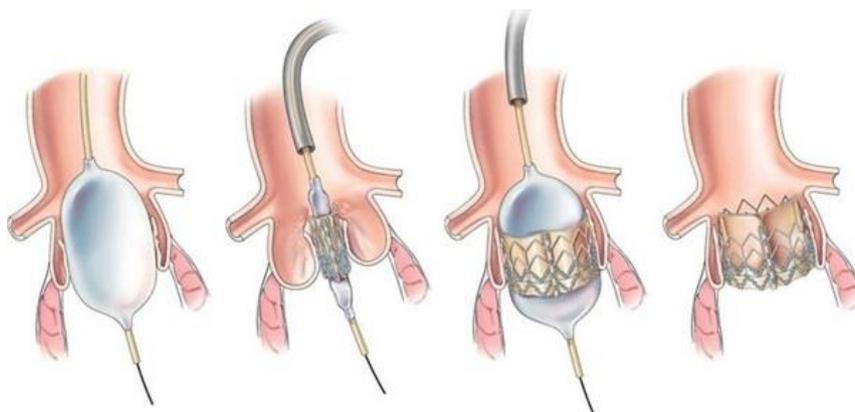


Рис. 1. Процесс TAVI

Последние исследования показывают, что специфические осложнения TAVI часто связаны с несоответствием протеза и пациента, а также с неправильным позиционированием устройства. Большинство пери- и постпроцедурных осложнений зависят от оператора, однако физиологические движения пациентов во время доставки и установки устройства могут временно прерывать сердечный цикл, ограничивать кровоток и вызывать дыхательные проблемы. Эти осложнения в значительной степени зависят от качества интраоперационной визуализации, необходимой для точного позиционирования устройства. Современные системы ангиографии, интегрированные с коммерчески доступным программным обеспечением, призваны облегчить навигацию во время TAVI и снизить риск осложнений. Такие продукты, как HeartNavigator от Philips, syngo Aortic Valve Guide от Siemens Healthcare, Innova HeartVision от GE Healthcare и C-THV от Paeon Inc., были успешно внедрены в клиническую практику. Существующие системы навигации выравнивают предоперационно сгенерированную 3D-анатомическую модель аортального корня, основанную на компьютерной томографии (КТ), и накладывают ее на живые флюороскопические изображения во время

¹ Работа выполнена при поддержке РФФ, проект № 24-19-00084 (<https://rscf.ru/project/24-19-00084/>)

позиционирования клапана, обеспечивая оптимальную ориентацию ангиографической системы и сосудистый доступ.

Искусственный интеллект (ИИ) уже произвел революцию в кардиологии, помогая в интерпретации медицинских изображений и разработке моделей риска для пациентов с сердечными заболеваниями. Применение ИИ в процедурах TAVI может значительно улучшить отбор пациентов, планирование процедур, мониторинг после имплантации и способствовать оптимизации результатов лечения пациентов. В статье [1] авторами Миной М. Бенджамин и Марком Г. Раббат исследуется растущая роль ИИ в процедурах TAVI и оценивается его потенциальное воздействие, с особым акцентом на способность ИИ улучшить отбор пациентов, планирование процедур, мониторинг после имплантации и способствовать оптимизации результатов лечения пациентов.

Важность оптимального позиционирования клапана подтверждается исследованием [2] авторов М. Бьянчи и др. Исследование посвящено оценке механики сжатия коммерческих клапанов Edwards SAPIEN и альтернативного полимерного клапана Polynova и влиянию различных позиций установки TAVR с использованием численных моделей, специфичных для пациентов. Результаты показали, что Polynova лучше выдерживает процесс сжатия по сравнению с SAPIEN, и указали на роль отложений кальция в субоптимальном анкерировании клапана, что приводит к паравальвулярным утечкам.

Другие исследования подчеркивают значимость точной диагностики и прогнозирования осложнений TAVI с использованием ИИ. В статье [3] авторы рассматривается влияние TAVR на классификацию пациентов с аортальным стенозом с использованием кардиомеханических модальностей и машинного обучения. Результаты показали, что до TAVR пациенты могут быть классифицированы как имеющие аортальный стеноз, но после TAVR они не могут быть классифицированы как здоровые.

В исследовании [4] авторами предлагается структура сверточной нейронной сети для прогнозирования паравальвулярной утечки на основе предоперационных КТ-изображений. Модель достигла точности 79% при использовании четырехкратной кросс-валидации.

Статья [5] авторов Г. Чжана и др. предлагает систему для прогнозирования аортальной регургитации после TAVR и идентификации наилучшего клапана для TAVR с использованием метода конечных элементов. Модель достигла точности 90.9% при прогнозировании риска регургитации и оптимального размера клапана, демонстрируя высокую ценность этой модели для планирования процедур.

Недавнее исследование [6] авторов Д. В. Данилова и др. описывает оригинальный алгоритм на основе многозадачного обучения для отслеживания анатомических ориентиров и маркировки ключевых точек на аортальном клапане и системе доставки во время TAVI. Алгоритм включает девять нейронных сетей для прогнозирования 11 ключевых точек интереса с использованием различных архитектур, таких как MobileNet V2, ResNet V2, Inception V3, Inception ResNet V2 и EfficientNet B5. Архитектуры ResNet V2 и MobileNet V2 показали наилучшее соотношение точности и времени прогнозирования, предсказывая метки ключевых точек и координаты с точностью 97/96% и средним абсолютным отклонением 4.7/5.6% соответственно. Исследование демонстрирует, что такие нейронные сети способны выполнять прогнозирование в реальном времени, способствуя правильному позиционированию клапана во время TAVI.

В работе [7] авторов В. В. Лаптева и Н. А. Кочергина используется набор данных из [6], состоящий из 35 видеозаписей процедур TAVI. Система визуализации базируется на технологии детекции объектов с использованием нейронных сетей семейства YOLO. Для улучшения качества входных данных использовались сверточные нейронные сети, а именно автоэнкодеры. Результаты показали, что автоэнкодер способен восстановить информативность зашумленного изображения с 40 до 75%, повышая точность обнаружения объектов. Система достигла конечной точности по метрике качества MAP – 51,9%, что подтверждает её эффективность для визуального ассистирования в реальном времени.

Таким образом, использование ИИ в процедурах TAVI представляет собой актуальную и перспективную область исследований, требующую дальнейшего развития для улучшения клинических результатов и минимизации осложнений у пациентов.

1. Методология

В этом разделе описаны использованные методы для анализа и обработки данных, а также построение и обучение модели. Начнем с детального анализа датасета, который включает описание структуры данных и статистических характеристик, а затем перейдем к методам предобработки

данных, таким как аугментация и нормализация. Наконец, будет представлена архитектура предложенной модели и подходы к ее обучению и оценке.

1.1. Датасет и анализ данных

Данный исследовательский проект использует датасет "Aortography keypoint tracking for TAVI" [6], содержащий оригинальные аортографические изображения, собранные в период с 2015 по 2018 годы во время имплантации 14 саморасширяющихся биопротезов аортального клапана CoreValve у пациентов с аортальным стенозом. Все процедуры TAVI были проведены одним и тем же оператором в отделении сердечно-сосудистой хирургии НИИ комплексных проблем сердечно-сосудистых заболеваний.

Во время TAVI было собрано 35 видеопоследовательностей с разрешением 1000x1000 пикселей и 8-битной глубиной. Общий объем данных составил 3730 изображений в градациях серого, из которых 2984 (80%) использовались для обучения, а 746 (20%) - для валидации нейронных сетей. Датасет включает изображения, иллюстрирующие три ключевых этапа процедуры: позиционирование катетера и системы доставки, начало втягивания капсулы и высвобождение протеза, и развертывание протеза.

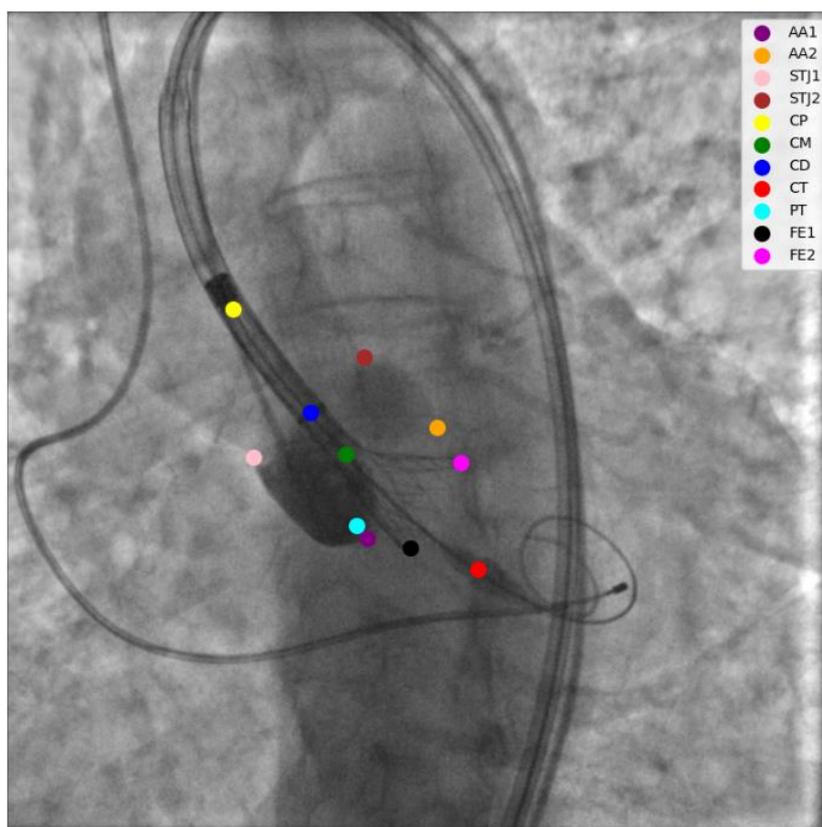


Рис. 2. Визуализация разметки на клапане

Каждое изображение в датасете аннотировано до 11 ключевых точек, которые разделены на три категории: анатомические ориентиры, ориентиры системы доставки и дополнительные ориентиры [8].

Анатомические ориентиры:

- Синотубулярное соединение (STJ1, STJ2) — дополнительные ориентиры для определения плоскости аортального кольца.
- Аортальный корень (AA1, AA2) — ключевые ориентиры для процедуры TAVI.

Ориентиры системы доставки:

- Средняя точка катетера (CM) — ориентир синотубулярной части стента.
- Проксимальный конец катетера (CP) — определяет степень извлечения протеза.
- Дистальный конец катетера (CD) — определяет степень извлечения протеза.
- Конец катетера (CT) — определяет местоположение катетера и плоскость аортального кольца.

Дополнительные ориентиры:

- Pigtail (PT) — ориентир для имплантации клапана, указывающий на плоскость аортального кольца.
- Дистальная часть стента (FE1, FE2) — определяет местоположение стента во время имплантации и его отклонение от плоскости аортального корня.

Для визуализации трех последовательных этапов использовались серии изображений во время контрастного впрыскивания. Разметка данных была выполнена с использованием платформы Supervisely AI.

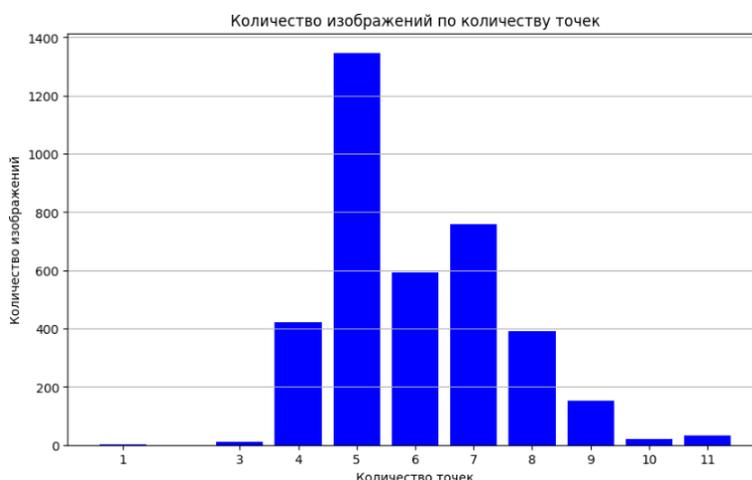


Рис. 3. Количество изображений по количеству точек

Анализ данных показал, что каждая последовательность содержит разное количество изображений (рисунок 3), варьирующееся от 29 до 325. Каждое изображение аннотировано различным количеством ключевых точек, что создает дополнительные сложности для обучения моделей. Распределение изображений по количеству ключевых точек было визуализировано в виде гистограммы, что позволило лучше понять структуру данных и подготовить их для обучения модели.

1.2. Подготовка данных

В данной главе рассматривается подготовка данных для обучения модели, основанной на сверточной и рекуррентных нейронных сетях [9], для задачи отслеживания ключевых точек [10] в аортографии.

Для начала изображения и аннотации были организованы в виде последовательностей. Каждая последовательность включает до 10 изображений, которые используются для анализа и предсказания ключевых точек на следующем, 11-ом изображении (рисунок 4). Этот подход помогает [11] модели учитывать временную динамику и пространственные изменения, что особенно важно для медицинских изображений, где контекст и последовательность имеют критическое значение.

Разработанный класс датасета загружает изображения и соответствующие аннотации, преобразовывая их в удобный формат для подачи в нейронную сеть. Аннотации включают до 11 ключевых точек, каждая из которых представляет определенные анатомические или инструментальные маркеры, важные для процедуры TAVI. Для каждой последовательности изображений рассчитываются индексы, обеспечивающие доступ к изображениям и аннотациям в нужном порядке.

Для каждой последовательности из 10 изображений создается тензор, который затем передается модели. Также создается тензор аннотаций для каждой ключевой точки, причем отсутствующие точки заменяются на нулевые значения. Это позволяет модели обрабатывать последовательности с переменным количеством ключевых точек. В дополнение к этому, была реализована функция коллатора, которая собирает данные в батчи для эффективной обработки нейронной сетью.

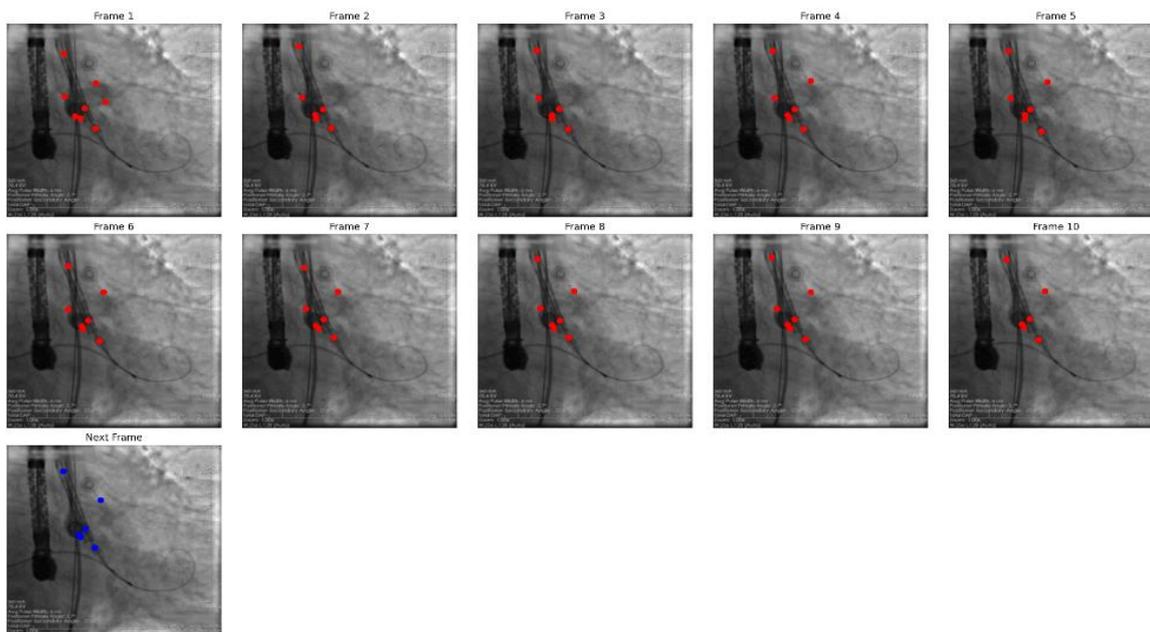


Рис. 4. Выборка из датасета

2. Архитектура модели

В этой главе рассматривается структура и принцип работы модели, использованной для задачи отслеживания ключевых точек в аортографии. Будет описано, как была разработана модель, основанная на комбинировании сверточных и рекуррентных нейронных сетей, что позволяет эффективно анализировать последовательности изображений и предсказывать ключевые точки на них.

2.1. Обзор модели

Модель состоит из двух ключевых компонентов: сверточной нейронной сети (CNN) и рекуррентной нейронной сети (RNN) [12]. Сверточная сеть предназначена для извлечения пространственных признаков из изображений, в то время как рекуррентная сеть обрабатывает временную информацию, что особенно важно для анализа последовательностей изображений, таких как медицинские видеокдры.

Сначала была использована простая архитектура сверточной сети [13], состоящая из нескольких слоев сверток и max-pooling слоев. Эта базовая архитектура эффективно уменьшала пространственное разрешение изображений, выделяя важные признаки и паттерны.

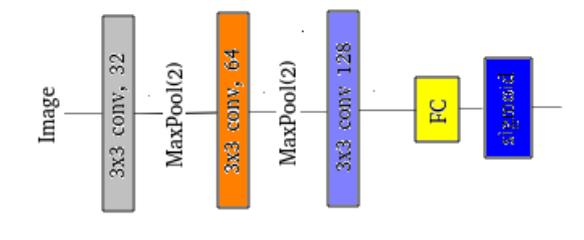


Рис. 5. Простая CNN

Позже для улучшения выделения высокоуровневых признаков была внедрена архитектура ResNet18. ResNet (Residual Network) [14] известна своей способностью обрабатывать глубокие нейронные сети благодаря использованию остаточных соединений, что помогает избежать проблем исчезающего градиента и улучшает обучение. ResNet18, как мощная архитектура CNN, позволяет извлекать более сложные и значимые признаки из изображений.

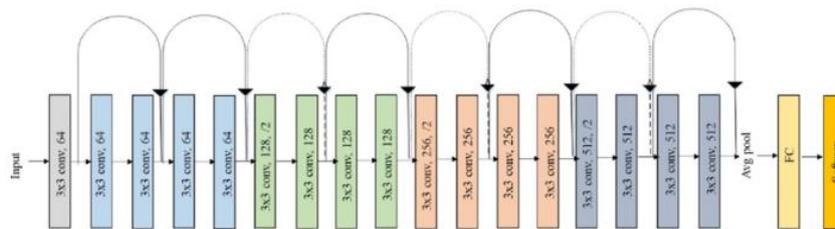


Рис. 6. ResNet18

После обработки изображений с помощью CNN, полученные признаки передаются в рекуррентную нейронную сеть (RNN), а именно в Long Short-Term Memory (LSTM) [15] слой. LSTM слои предназначены для работы с последовательными данными и могут учитывать временные зависимости между кадрами. Это особенно важно для медицинских изображений, где изменения между последовательными кадрами могут содержать критически важную информацию.

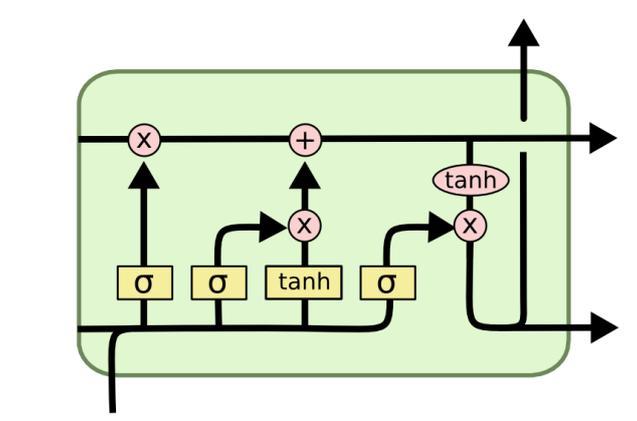


Рис. 7. Архитектура LSTM

Рекуррентная часть модели анализирует временные последовательности признаков, полученных от CNN, и предсказывает координаты ключевых точек на следующем кадре. Для этого используются два линейных слоя: один для предсказания координат ключевых точек, другой для предсказания их наличия. Такой подход позволяет модели не только предсказывать местоположение ключевых точек, но и определять, присутствуют ли они на изображении.

В результате использования комбинации сверточных и рекуррентных нейронных сетей [16] модель способна эффективно обрабатывать пространственную и временную информацию, что обеспечивает высокую точность и надежность предсказаний. Таким образом, архитектура модели включает в себя мощные инструменты для анализа изображений и временных данных, что делает её подходящей для сложных задач медицинской визуализации, таких как отслеживание ключевых точек в аортографии.

2.2. Функция потерь

Функция потерь [17], используемая для обучения модели, учитывает два аспекта: точность предсказанных координат ключевых точек и вероятность их наличия на изображении. Для этого была разработана функция потерь, включающая в себя три основных компонента:

Среднеквадратичная ошибка (MSE) используется для оценки точности предсказанных координат ключевых точек. Она вычисляется как среднее квадратичное отклонение между предсказанными и истинными координатами ключевых точек. Пусть (P) — матрица предсказанных координат ключевых точек, а (T) — матрица истинных координат ключевых точек. Тогда для каждой ключевой точки:

$$\text{MSE Loss}_i = \frac{1}{2} \sum_{k=1}^K |P_{i,k} - T_{i,k}|^2 \quad (1)$$

где (i) — индекс ключевой точки, (K) — количество ключевых точек. MSE Loss минимизирует отклонение предсказанных координат от истинных значений, обеспечивая точное расположение ключевых точек на изображении.

- Бинарная кросс-энтропия (BCE) отвечает за оценку вероятности наличия ключевых точек на изображении. Она вычисляется как бинарная кросс-энтропия между предсказанной вероятностью

наличия точки и истинной меткой (0 или 1). Пусть $(P_{\text{предс}})$ — предсказанная вероятность наличия ключевых точек, а $(T_{\text{предс}})$ — истинная метка наличия точки (0 или 1). Тогда:

$$\text{BCE Loss}_i = -[T_{\text{presence},i} \log(P_{\text{presence},i}) + (1 - T_{\text{presence},i}) \log(1 - P_{\text{presence},i})] \quad (2)$$

BCE Loss минимизирует расхождение между предсказанной вероятностью и истинной меткой наличия точки, улучшая способность модели точно определять наличие ключевых точек.

- Общая функция потерь объединяет MSE Loss и BCE Loss для учета обеих задач: предсказание координат и вероятность наличия точки. Общая функция потерь определяется как сумма двух компонент

$$\text{TotalLoss} = \frac{1}{N} \sum_{i=1}^N [\text{MSE Loss}_i + \text{BCE Loss}_i] \quad (3)$$

3. Эксперименты и результаты

В данном разделе описаны проведенные эксперименты и полученные результаты, направленные на оценку эффективности предложенной модели для отслеживания ключевых точек в аортографии. Мы рассмотрим настройки экспериментов, полученные метрики и проведем анализ результатов.

3.1. Настройки экспериментов

Для обучения и валидации модели использовался датасет "Aortography keypoint tracking for TAVI". Датасет был разделен на обучающую и тестовую выборки в соотношении 80/20. В процессе обучения использовалась расширенная архитектура ResNet50 для извлечения признаков из изображений, а также LSTM для учета временной последовательности кадров. Обучение модели проводилось с использованием оптимизатора AdamW [18] и планировщика OneCycleLR [19] для регулирования скорости обучения.

Процесс подготовки данных включал применение следующих аугментаций для обучающих данных:

Анатомические ориентиры:

Случайное горизонтальное и вертикальное отражение

- Случайный поворот на 10 градусов
- Регулировка яркости, контрастности, насыщенности и оттенка.

Для тестовых данных применялась только операция изменения размера изображения. Обучение модели проводилось на графическом процессоре NVIDIA с использованием фреймворка PyTorch. Модель обучалась в течение 150 эпох с батчем размером 16 для обучающей выборки и 8 для тестовой выборки. Код обучения находится по ссылке [20].

Функция потерь модели состояла из двух компонент: MSE Loss для предсказанных координат ключевых точек и BCE Loss для вероятностей наличия ключевых точек. Таким образом, итоговая функция потерь определялась как сумма этих двух компонент.

3.2. Результаты

В данной работе мы провели эксперименты по обучению трех различных моделей для задачи отслеживания ключевых точек в аортографии. Были использованы следующие архитектуры: простая сверточная нейронная сеть, ResNet18 и ResNet50. Каждая модель была обучена и протестирована на одном и том же наборе данных для обеспечения сравнимости результатов.

Обучение проводилось с использованием оптимизатора AdamW с начальными параметрами скорости обучения $\text{lr}=0.001$ и шедулером OneCycleLR, который управляет изменением скорости обучения на протяжении всего процесса обучения. Это помогло достичь более стабильного и быстрого сходимости моделей.

Обучение каждой модели проводилось в течение 150 эпох. На каждой эпохе модель тренировалась на обучающем наборе данных, а затем оценивалась на валидационном наборе. Для каждой модели фиксировались значения потерь на обучающем и валидационном наборах, что позволило отслеживать прогресс обучения и выявлять моменты переобучения.

Для оценки производительности модели использовалась совокупная функция потерь, включающая потери от предсказанных координат ключевых точек и потери от наличия или отсутствия ключевых точек. Это позволило модели эффективно обучаться, учитывая как точность позиционирования ключевых точек, так и уверенность в их наличии.

Графики обучения (рисунок 8) демонстрируют снижение значений потерь на протяжении эпох для каждой модели. Эти графики позволяют визуально оценить эффективность обучения и сходимости моделей.

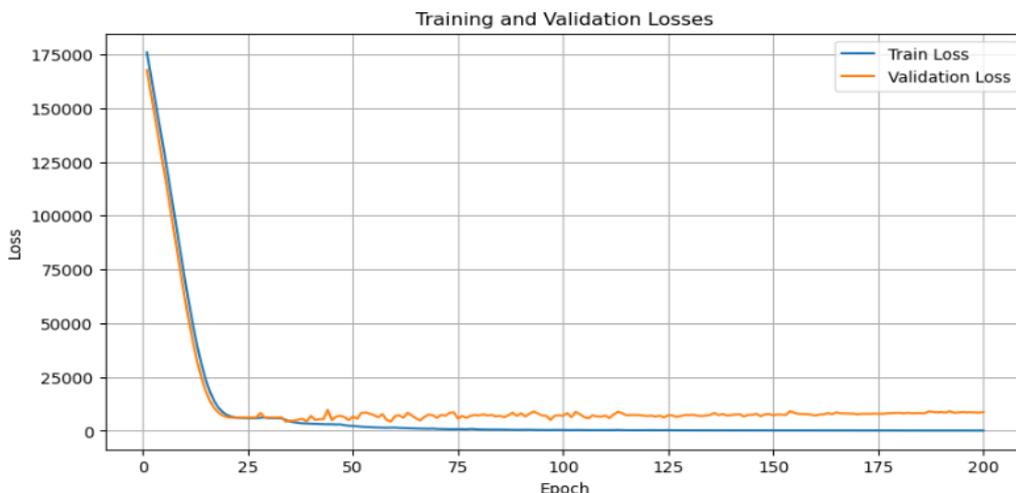


Рис. 8. Динамика изменения значения функции потерь

Для оценки точности моделей использовались метрики среднеквадратичной ошибки (MSE), средней абсолютной ошибки (MAE) и корня средней квадратичной ошибки (RMSE). Также учитывались метрики классификации, такие как Precision, Recall, F1 score и Accuracy.

Ниже представлена таблица, сравнивающая наши результаты с результатами, представленными в аналогичных исследованиях.

Таблица 1. Сравнение моделей по метрикам классификации

Модель	Precision	Recall	F1 score	Accuracy
ResNet V2 FT	0.97	0.97	0.93	0.97
MobileNet V2 FT	0.96	0.97	0.93	0.97
Inception V3 FT	0.96	0.97	0.93	0.97
EfficientNet B5	0.96	0.97	0.93	0.97
Yolov8l	0.61	0.52	0.55	0.6
Our ResNet18+LSTM	0.98	0.97	0.93	0.97
Our ResNet50+LSTM	0.95	0.93	0.91	0.95
Our CNN+LSTM	0.81	0.75	0.79	0.8

Таблица 2. Сравнение моделей по метрикам регрессии

Модель	MAE	RMSE	MSE
ResNet V2 FT	0.0350	0.049	0.002
MobileNet V2 FT	0.045	0.066	0.004
Inception V3 FT	0.0350	0.049	0.005
EfficientNet B5	0.0350	0.049	0.010
Yolov8l	0.442	0.572	0.032
Our ResNet18+LSTM	0.0370	0.052	0.003
Our ResNet50+LSTM	0.0521	0.078	0.010
Our CNN+LSTM	0.216	0.124	0.023

Проведенные эксперименты включали обучение и тестирование трех различных моделей: простой сверточной нейронной сети (CNN+LSTM), модели на основе ResNet18+LSTM и модели на основе ResNet50+LSTM. Модель ResNet18+LSTM показала наилучшие результаты среди всех протестированных моделей. Её точность (Precision) составила 0.98, F1 Score 0.93 и точность классификации (Accuracy) 0.97. Эти результаты сравнимы с показателями продвинутых моделей из литературы, таких как ResNet V2 и MobileNet V2. Модель ResNet50+LSTM также продемонстрировала высокие результаты, но несколько уступала ResNet18+LSTM. Её точность (Precision) составила 0.95, F1 Score 0.91 и точность классификации (Accuracy) 0.95. Простая модель CNN+LSTM показала значительно более низкие результаты, с точностью (Precision) 0.81, F1 Score 0.79 и точностью классификации (Accuracy) 0.80, что свидетельствует о её ограниченных возможностях в данной задаче.

Модель Yolov8l показала худшие результаты по всем метрикам классификации и регрессии, что подчеркивает важность выбора подходящей архитектуры для конкретной задачи. Метрики регрессии также подтвердили превосходство моделей ResNet18+LSTM и ResNet50+LSTM. По метрикам средней абсолютной ошибки (MAE) модели показали результаты 0.037 и 0.0521 соответственно, что сопоставимо с результатами продвинутых моделей, таких как ResNet V2 FT и Inception V3 FT.

На рисунке 9 представлены результаты работы модели.

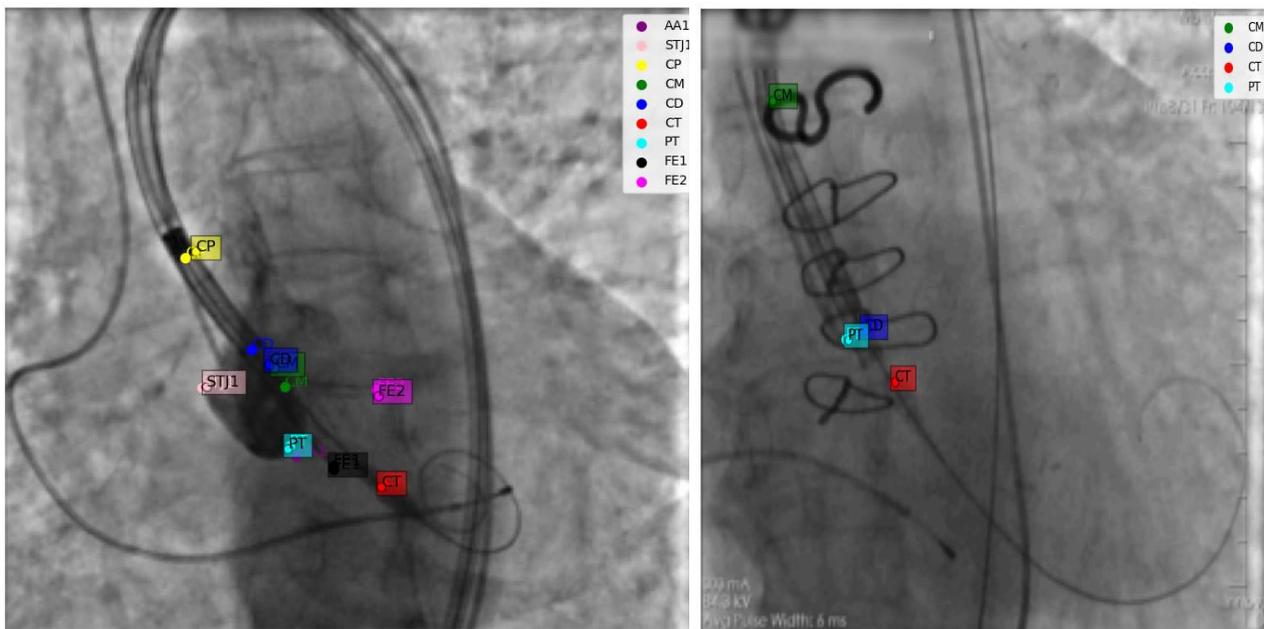


Рис. 9. Результаты работы модели

Точки, обозначающие истинные значения, отмечены как обычные точки, в то время как предсказания модели отображены точками того же цвета, но с выделенными в квадрат названиями точек. Это позволяет наглядно сравнить реальные и предсказанные положения ключевых точек, демонстрируя точность и качество работы модели.

4. Заключение

В данной работе рассмотрена задача отслеживания ключевых точек в аортографии с использованием модифицированной архитектуры сверточных и рекуррентных нейронных сетей. Этот метод имеет большое значение для повышения точности и безопасности процедуры имплантации транс-катетерного аортального клапана (TAVI), где правильное позиционирование клапана критически важно для успешного исхода. Исследование началось с анализа датасета "Aortography keypoint tracking for TAVI", который включает серию изображений, полученных во время процедур TAVI. Эти изображения содержат метки 11 ключевых точек, представляющих анатомические ориентиры и элементы системы доставки. Эти ключевые точки были тщательно размечены с использованием платформы Supervisely AI, что обеспечило высокую точность данных для обучения и валидации моделей. Для обработки данных была разработана специальная архитектура модели, состоящая из двух основных частей: сверточной нейронной сети (CNN) и рекуррентной нейронной сети (RNN). Изначально использовалась простая сверточная сеть с тремя слоями, но позже было решено перейти на более сложную архитектуру ResNet50, которая показала лучшую эффективность в извлечении признаков из изображений. Рекуррентная часть модели была представлена LSTM, что позволило учитывать временную последовательность изображений и улучшить точность предсказаний. Функция потерь модели была разработана с учетом двух задач: предсказание координат ключевых точек и вероятности их наличия. Использовалась комбинация MSE Loss для координат и BCE Loss для вероятностей наличия точек. Это позволило модели эффективно обучаться на данных, учитывая как точность позиционирования ключевых точек, так и уверенность в их наличии.

В ходе экспериментов проводилось обучение модели на датасете с использованием аугментаций данных для улучшения обобщающей способности модели. Обучение проводилось с использованием оптимизатора AdamW и планировщика OneCycleLR, что позволило эффективно регулировать скорость обучения и достигнуть оптимальных результатов. Результаты экспериментов показали, что предложенная модель успешно справляется с задачей отслеживания ключевых точек в аортографии,

демонстрируя высокую точность и надежность предсказаний. Визуализация предсказанных точек на изображениях показала, что модель способна точно определять ключевые точки, необходимые для корректного выполнения процедуры TAVI.

Результаты сравнения моделей по метрикам классификации и регрессии показали, что модель ResNet18+LSTM продемонстрировала высокую точность и надежность, превосходя другие модели, такие как YOLOv8 и CNN+LSTM. Метрики этой модели показали лучшие результаты по сравнению с существующими решениями, что подтверждает ее эффективность в данной задаче.

Несмотря на достигнутые результаты, остаются направления для дальнейших исследований и улучшений. Во-первых, возможно улучшение точности модели за счет использования более сложных архитектур и методов регуляризации. Во-вторых, важно продолжить работу по увеличению объема и разнообразия данных для обучения, что позволит модели лучше обобщать и справляться с различными ситуациями, возникающими в ходе процедур TAVI. В заключение, данная работа показала, что применение современных методов машинного обучения, таких как CNN и LSTM, позволяет значительно улучшить точность и надежность процедур медицинской визуализации. Предложенная модель имеет потенциал для внедрения в клиническую практику, что позволит улучшить исходы процедур TAVI и повысить безопасность пациентов.

Литература

1. Benjamin M. M., Rabbat M.G. Artificial Intelligence in Transcatheter Aortic Valve Replacement: Its Current Role and Ongoing Challenges. Michael Henein, Academic Editor and Ayman El-Baz, Academic Editor.
2. Bianchi M., Ghosh R.P., Marom G., Slepian M.J., Bluestein D. Simulation of Transcatheter Aortic Valve Replacement in patient-specific aortic roots: Effect of crimping and positioning on device performance. 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Milan, Italy, 2015, pp. 282-285, doi: 10.1109/EMBC.2015.7318355.
3. Yang C., Ojha B., Aranoff N.D., Green P., Tavassolian N. Classification of Aortic Stenosis Before and After Transcatheter Aortic Valve Replacement Using Cardio-mechanical Modalities. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), Montreal, QC, Canada, 2020, pp. 2820-2823, doi: 10.1109/EMBC44109.2020.9176321.
4. Wang Z.H., et al. Prediction of paravalvular leak post transcatheter aortic valve replacement using a convolutional neural network. 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), Washington, DC, USA, 2018, pp. 1088-1091, doi: 10.1109/ISBI.2018.8363760.
5. Zhang G., Pu M., Gu Y., Zhou X. Predicting Aortic Regurgitation After Transcatheter Aortic Valve Replacement by Finite Element Method. IEEE Access, vol. 7, pp. 64315-64322, 2019, doi: 10.1109/ACCESS.2019.2916762.
6. Danilov V.V., Klyshnikov K.Y., Gerget O.M., Skirnevsky I.P., Kutikhin A.G., Shilov A.A., Ganyukov V.I., Ovcharenko E.A. Aortography Keypoint Tracking for Transcatheter Aortic Valve Implantation Based on Multi-Task Learning. Front Cardiovasc Med. 2021 Jul 19;8:697737. doi: 10.3389/fcvm.2021.697737.
7. Лантев В.В., Кочергин Н.А. Применение технологии object detection в задаче обнаружения ключевых точек аортографии. Комплексные проблемы сердечно-сосудистых заболеваний. 2024;13(1):144-151. <https://doi.org/10.17802/2306-1278-2024-13-1-144-151>.
8. Белов Ю.В., Комаров Р.Н., Россейкин Е.В., Винокуров И.А., Степаненко А.Б. Анатомические особенности корня аорты с хирургических позиций. Кардиология и сердечно-сосудистая хирургия. 2012;5(3):4-8.
9. Полковникова Н. А. Исследование методов и алгоритмов компьютерного зрения на основе свёрточных и рекуррентных нейронных сетей / Н. А. Полковникова // Эксплуатация морского транспорта. – 2020. – № 3(96). – С. 154-168. – DOI 10.34046/aumsuomt96/21. – EDN TQLDDM.
10. Гасан И. С. Детектирование объектов и ключевых точек объектов с помощью нейронной сети YOLO v7 на базе умной камеры ОАК-D-PoE / И. С. Гасан, А. В. Семенов // Цифровые технологии в образовании, науке, обществе : Материалы XVII Всероссийской научно-практической конференции, Петрозаводск, 22–24 ноября 2023 года. – Петрозаводск: Петрозаводский государственный университет, 2023. – С. 24-27. – EDN BPRIEW.
11. Бендерская Елена Николаевна, Никитин Кирилл Вячеславович Рекуррентная нейронная сеть как динамическая система и подходы к ее обучению // Информатика, телекоммуникации и управление. 2013. №4 (176).
12. Chuankun, li & Wang, Pichao & Wang, Shuang & Hou, Yonghong & Li, Wanqing. (2017). Skeleton-based action recognition using LSTM and CNN. 585-590. 10.1109/ICMEW.2017.8026287.
13. Chauhan R., Ghanshala K.K. and Joshi R.C. Convolutional Neural Network (CNN) for Image Detection and Recognition, 2018 First International Conference on Secure Cyber Computing and Communication (ICSCCC), Jalandhar, India, 2018, pp. 278-282, doi: 10.1109/ICSCCC.2018.8703316.
14. He K., Zhang X., Ren S. and Sun J. Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 770-778, doi: 10.1109/CVPR.2016.90.
15. Pulver A. and Lyu S. LSTM with working memory, 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, USA, 2017, pp. 845-851, doi: 10.1109/IJCNN.2017.7965940.

16. *Гафаров Ф. М.* Искусственные нейронные сети и приложения: учеб. пособие – Казань: Изд-во Казан. ун-та, 2018. – 121 с.
17. *Cho K., Roh J. -h., Kim Y. and Cho S.* A Performance Comparison of Loss Functions, 2019 International Conference on Information and Communication Technology Convergence (ICTC), Jeju, Korea (South), 2019, pp. 1146-1151, doi: 10.1109/ICTC46691.2019.8939902.
18. *Zhou P., Xie X, Lin Z. and Yan S.* Towards Understanding Convergence and Generalization of AdamW, in IEEE Transactions on Pattern Analysis and Machine Intelligence, doi: 10.1109/TPAMI.2024.3382294.
19. *Smith L.N. and Topin N.* Super-convergence: Very fast training of neural networks using large learning rates, Proc. SPIE, vol. 11006, May 2019, Art. no. 1100612.
20. <https://github.com/kn-ru/aortography-keypoint-tracking.git>.