

Санкт-Петербургский государственный университет

Кафедра системного программирования

Группа 23.Б10-мм

Классификация заболеваний щитовидной железы по снимкам УЗИ

Кушнир Артем Юрьевич

Отчёт по учебной практике
в форме «Решение»

Научный руководитель:
доцент кафедры системного программирования, к. ф.-м. н., Гориховский В.И.

Санкт-Петербург
2024

Оглавление

Введение	3
1. Постановка задачи	5
2. Обзор	6
2.1. Обзор существующих решений	6
2.2. Обзор используемых технологий	11
2.3. Выводы	11
3. Обзор датасета	13
4. Описание решения	15
4.1. Алгоритм работы	15
4.2. Сбор признаков	16
4.3. Отбор и обработка признаков	17
5. Эксперимент	19
5.1. Дизайн эксперимента	19
5.2. Условия эксперимента	19
5.3. Исследовательские вопросы	19
5.4. Метрики	20
5.5. Результаты	20
5.6. RQ3	21
5.7. Обсуждение результатов	22
5.8. Угрозы нарушения корректности	22
Заключение	23
Список литературы	24

Введение

Заболевания щитовидной железы представляют собой значимую группу патологии, которая затрагивает широкий круг населения и может вызывать серьезные нарушения в обмене веществ и в общем состоянии здоровья. Всемирная организация здравоохранения отмечает, что заболеваемость болезнями щитовидной железы с каждым годом растёт.[4] Зачастую это связано с тем, что около трети населения Земли живет на территориях с дефицитом йода, а это, в свою очередь, способствует развитию йододефицитных заболеваний щитовидной железы.[22]

Большая часть заболеваний не представляет серьезной угрозы на ранней стадии, поэтому очень важно как можно быстрее выявить патологию; иначе заболевание может переросить в серьезные осложнения и в некоторых случаях даже в летальный исход.[11]

Оценку состояния щитовидной железы можно провести с помощью нескольких методов визуализации, таких как рентгенография, радионуклидная визуализация, ультразвуковое исследование (УЗИ), компьютерная и магнитно-резонансная томография.[3] Однако большинство этих процедур являются инвазивными либо дорогостоящими, поэтому они не подходят для повсеместного использования в качестве первичной диагностики пациентов.

Одним из лучших решений для первичной диагностики является УЗИ. Из плюсов можно выделить неинвазивность, безопасность и доступность;[20] однако ультразвуковые изображения имеют низкое пространственное разрешение и содержат множество артефактов из-за ультразвуковой дифракции. Также такая диагностика сильно зависит от опыта врача и не всегда позволяет определить характер узла. Решением данной проблемы может стать применение методов машинного обучения и нейросетей для предварительной обработки изображения, сегментации, выделения признаков и классификации заболеваний. Это позволит с высокой вероятностью направлять нужных пациентов на дополнительное более точное обследование.

В данной работе будет проведен анализ различных подходов и алгоритмов для классификации снимков УЗИ, с целью выделения наиболее эффективных алгоритмов.

1. Постановка задачи

Данное исследование представляет собой работу, включающую два ключевых направления: сегментация изображений и обучение моделей для классификации заболеваний щитовидной железы. В рамках моей работы основное внимание уделяется обучению моделей. Целью работы является выбор оптимального подхода и алгоритмов для распознавания поражений щитовидной железы. Для её выполнения были поставлены следующие задачи:

1. Анализ предметной области и подходов к распознаванию с целью выбора оптимальных алгоритмов для сравнения;
2. Сбор признаков;
3. Отбор наиболее значимых признаков;
4. Сравнение выбранных алгоритмов;
5. Анализ качества распознавания;

2. Обзор

2.1. Обзор существующих решений

После предварительной работы с изображением наступает этап классификации, который заключается в разделении объектов (в нашем случае изображений) на группы (классы) на основе их общих свойств или характеристик. Можно выделить два основных подхода к классификации: применение нейронных сетей и использование алгоритмов классического машинного обучения. В дальнейшем обзоре будет уделено отдельное внимание анализу готовых решений, предоставляемых крупными корпорациями..

Также стоит отметить, что на снимке УЗИ помимо интересующей нас щитовидной железы расположено много других объектов, таких как кровеносные сосуды, шейные лимфатические узлы, мышцы, нервные структуры. Это вместе с тем, что на снимках УЗИ часто появляются дефекты в виде пятен и артефактов, может существенно повлиять на выделение признаков и сегментацию, которые оказывают большое влияние на точность предсказания классических алгоритмов классического машинного обучения. Нейросети ведут себя более устойчиво к таким особенностям, однако эти факторы также могут оказывать влияние на результаты классификации нейронных сетей.

2.1.1. Готовые инструменты

- **Edison AI**[8] — это платформа искусственного интеллекта, разработанная подразделением GE Healthcare, которая интегрирует методы машинного обучения в медицинские системы и рабочие процессы. Эта платформа предоставляет решения для анализа медицинских изображений, поддержки принятия решений и улучшения диагностики. Эта платформа способна автоматически по снимкам УЗИ, МРТ, КТ и других методов визуализации выявлять патологии, такие как опухоли, кисты, узлы, переломы и другие аномалии, в том числе патологии щитовидной железы. Эта

платформа поддерживает международный стандарт DICOM, который используется для хранения и передачи медицинских изображений. Из минусов можно выделить то, что Edison AI тесно связана с оборудованием компании GE HealthCare и на нем работает более оптимально. Также к минусам Edison AI можно отнести высокую стоимость, сложность внедрения в медицинские учреждения, а также высокие требования к вычислительным ресурсам.

- **Monai**[12] — это платформа для разработки решений на основе искусственного интеллекта в области медицинской визуализации. Monai был разработан NVIDIA и PyTorch Foundation, а его цель — предоставить исследователям, разработчикам и медицинским учреждениям удобные инструменты для создания моделей машинного обучения и искусственного интеллекта для анализа медицинских изображений. Эта платформа с открытым исходным кодом, что позволяет исследователям и всем интересующимся этой областью людям, дорабатывать, адаптировать платформу под себя. Платформа построена на PyTorch, который является одним из наиболее популярных фреймворков для глубокого обучения, что делает Monai совместимым с существующими решениями и исследованиями в области ИИ. Monai также поддерживает различные модальности среди которых есть все наиболее популярные способы визуализации: МРТ, КТ, УЗИ, Рентгеновские снимки. Несмотря на то, что Monai предоставляет много различных инструментов, для эффективной интеграции платформы необходимы знания в области машинного обучения, а также чаще всего может потребоваться дообучение, так как Monai не предоставляет стандартизированных решений и больше ориентирована на исследовательские проекты.

2.1.2. Нейронные сети

Методы гдубоко обучения способны сами находить скрытые закономерности и признаки, которые оказывают наибольшее влияние на целевую переменную, это облегчает часть работы, в которой нужно пре-добрабытывать изображения и выделять признаки. Нейросети, несмотря на свою мощность в решении задач, часто страдают от ограниченной интерпретируемости, что затрудняет понимание их решений человеком. Для обучения нейронных сетей необходимо огромное количество данных, а также мощные вычислительные ресурсы.

Основные методы гдубоко обучения для задачи классификации изображений:

- Convolutional Neural Network (CNN)
- Vision Transformers (ViT)
- Generative Adversarial Network (GAN)
- U-Net
- Recurrent Neural Networks (RNN)

Наиболее популярным решением являются сверточные нейронные сети(CNN). Большинство существующих решений сконцентрированы на бинарной классификации, но в работе [7] выполнена мультиклассификация нормальной и патологической щитовидной железы с использованием архитектуры CNN, Xception. Эта работа особенно интересна тем, что нейросеть обучалась всего лишь на 917 изображениях УЗИ и показала высокую точность, в среднем на кроссвалидации из 10 частей, 0,97. .Результаты работы Xception превзошли другие архитектуры, которые показывали хорошие результаты в бинарной классификации(InceptionV3, DenseNet121), не только по точности, но и по времени обучения. Так как нейросети сильно страдают из-за нехватки данных, можно прибегнуть к созданию синтетических изображений путем

изменения различных параметров исходных изображений. Так в работе [1] обучающая выборка была увеличена с 527 до 631 800 объектов, что увеличило метрики на тестовой выборке. Для увеличения набора данных можно также воспользоваться генеративно-состязательной сетью (GAN), она генерирует новые изображения из случайного шума.

Vision Transformers - это архитектура нейронных сетей, основанная на механизме внимания (transformers), изначально разработанном для обработки последовательностей (например, текста), но адаптированная для задач компьютерного зрения. ViT был представлен Google Research в 2020 году и стал революционным подходом для классификации изображений, альтернативным традиционным сверточным нейронным сетям (CNN). Применяя механизм самовнимания к фрагментам изображений, Vision Transformers могут эффективно выявлять глобальные зависимости на изображениях, что позволяет им понимать контекст и взаимосвязи между различными частями изображения.[21]Так, в работе[10], была сделана гибридная модель ViT с базовой архитектурой сверточной нейронной сети для извлечения признаков для предварительной обработки входных ультразвуковых изображений.

2.1.3. Классические алгоритмы машинного обучения

Классические алгоритмы машинного обучения широко применяются наряду с нейронными сетями для задач классификации изображений. Однако ключевым отличием является необходимость предварительного ручного извлечения признаков для классических методов. Использование каждого пикселя изображения в качестве отдельного признака приводит к высокой размерности данных, что негативно влияет на результаты. Высокая размерность увеличивает вычислительную сложность модели, повышает вероятность переобучения и требует значительно большего объема данных для достижения удовлетворительного качества обучения.

Тем не менее, классические алгоритмы демонстрируют высокую эффективность в классификации медицинских изображений при условии, что набор данных имеет небольшой объем и признаки были качествен-

но выделены. Их способность извлекать информацию из компактных и информативных наборов признаков позволяет минимизировать риск переобучения и снизить вычислительные затраты. В медицинских приложениях, где объем доступных данных ограничен, такие алгоритмы остаются актуальными, особенно в случаях, когда эксперты могут выделить ключевые диагностически значимые маркеры.

Основные алгоритмы для задачи классификации:

- Logistic Regression
- K Nearest Neighbours (KNN)
- Decision Tree
- Random Forest
- Support Vector Machine (SVM)
- Gradient Boosting

Метод опорных векторов (SVM), популярное решение в этой области, он достаточно хорошо справляется с высокоразмерными данными, благодаря использованию гиперплоскости для разделения данных. В работе[5] использовался метод опорных векторов, основанный на ядре радиально-базисных функций Гаусса, и он показал высокие результаты, 0,983 точности для 59 изображений. Также на основе бинарных машин опорных векторов, были разработаны многоклассовые машины опорных векторов(MCSVM), что позволяет решать более сложные задачи. В статье[9] была проведена классификация и сравнения пяти различных реализаций MCSVM. Лучше всего себя показала ОАА-FSVM, которая использует подход "Один против всех".

Интересный подход в своей работе[2] предложил Puja Bharti, он использовал ансамблевую модель, основанную на двух классификаторах KNN, SVM и метаклассификаторе Random Forest.

2.2. Обзор используемых технологий

Для проведения экспериментов по классификации изображений был выбран язык программирования Python, что обусловлено его широким распространением и наличием развитой экосистемы библиотек и инструментов. Эти библиотеки, такие как OpenCV и scikit-learn, предоставляют мощные средства для обработки изображений и реализации алгоритмов машинного обучения. Удобство использования Python и его активное сообщество разработчиков делают его предпочтительным выбором для задач анализа и обработки изображений в научных и прикладных исследованиях.

2.3. Выводы

Нейронные сети и классические алгоритмы машинного обучения активно используются для классификации УЗИ-снимков. Выбор подходящего алгоритма зависит от качества, объёма и специфики данных. В настоящее время не существует универсального инструмента с открытым исходным кодом для диагностики заболеваний щитовидной железы, а большинство существующих исследований сосредоточено на применении методов глубокого обучения.

В рамках данного исследования предполагается использование датасета с ограниченным объёмом данных. В связи с этим предпочтение будет отдано классическим алгоритмам машинного обучения, которые зарекомендовали себя эффективными при малых объёмах обучающих выборок. Однако важно отметить, что исследования, посвящённые классическим методам, часто либо тестируются на очень ограниченном количестве изображений, что приводит к некорректности результатов, либо рассматривается только один конкретный алгоритм, что также ограничивает обоснованность выводов. В случае неудовлетворительных результатов будет рассмотрена возможность применения нейронных сетей для улучшения качества классификации.

В частности, будут исследованы следующие алгоритмы:


- **Метод опорных векторов (SVM)**, который хорошо зарекомендовал себя при работе с небольшими выборками данных.
- **Метод k-ближайших соседей (KNN) и логистическая регрессия**, которые демонстрируют высокую эффективность в задачах бинарной классификации.
- **Случайный лес (Random Forest)**, обладающий устойчивостью к шумам, что особенно важно для анализа ультразвуковых изображений, содержащих значительное количество артефактов.
- **Градиентный бустинг (Gradient Boosting)**, он хорошо справляется с выбросами и дисбалансом классов.
- **Логистическая регрессия (Logistic Regression)**, демонстрирует хорошие результаты в задачах классификации, если данные линейно разделимы.

3. Обзор датасета


У нас имеется набор данных DDTI: Thyroid Ultrasound Images, с сайта Kaggle[6] из 478 размеченных изображений, доступных для классификации узлов щитовидной железы. К каждому изображению приложен xml файл с мета информацией, набором точек, совокупность которых образует область, размеченную врачами, как подозрительную, а также номером TI-RADS. TI-RADS (Thyroid Imaging Reporting and Data System) — это система классификации ультразвуковых изображений щитовидной железы, которая используется для оценки риска злокачественности узлов на основе ультразвуковых характеристик.

- TI-RADS 1 — норма, без узлов (129 изображения).
- TI-RADS 2 — доброкачественные узлы (42 изображений).
- TI-RADS 3 — низкий риск (19 изображений).
- TI-RADS 4 — умеренный риск (243 изображений).
- TI-RADS 5 — высокий риск злокачественности (45 изображений).

Все изображения были разделены на два класса. К первому классу отнесены изображения УЗИ обеих долей щитовидной железы (174 изображения), ко второму классу — изображения УЗИ правой или левой доли щитовидной железы (304 изображения). Учитывая значительные различия между этими классами, изображения, относящиеся к меньшему классу (УЗИ обеих долей), были исключены из анализа для обеспечения однородности данных.



УЗИ одной доли



УЗИ обеих долей

Таким образом, для дальнейшего исследования был выбран набор из 301 изображения. Из исходных 478 изображений были исключены 174 изображения УЗИ обеих долей щитовидной железы, 2 повторяющихся изображения и одно не информативное изображение с большим количеством шума.

В оставшемся наборе данных наблюдается значительный дисбаланс классов. С целью упрощения задачи и улучшения классификации было принято решение о применении бинарной классификации. Изображения с TI-RADS от 1 до 3 были отнесены к отрицательному классу, а изображения с TI-RADS от 4 до 5 — к положительному классу.

4. Описание решения


4.1. Алгоритм работы

На начальном этапе исследования два из пяти выбранных алгоритмов — KNN и Logistic Regression — были исключены по следующим причинам:

- Плохо справляются с высокоразмерными данными
- Невозможность учитывать сложные нелинейные зависимости
- Плохо работают с зашумленными данными

В результате дальнейшей работы для решения задачи классификации были выбраны три классификатора: SVM, Random Forest и Gradient Boosting on Decision Trees. Также была рассмотрена возможность использования ансамблевой модели, объединяющей эти три классификатора, с целью повышения точности и устойчивости предсказаний.

Чтобы достигнуть поставленных задач, был составлен алгоритм решения:



4.2. Сбор признаков

Все рассматриваемые изображения содержат черную рамку с текстом, что может затруднить процесс классификации. В связи с этим, для подготовки изображений была применена процедура удаления рамки, включающая бинаризацию[13] изображений и последующий поиск внешних контуров[14].

В рамках данного исследования был выбран набор признаков, часто используемых в аналогичных работах для классификации изображений. Этот набор включает:

- 24 признаков GLCM матрицы.
- 12 wavelet-признаков.
- 6 признаков извлеченные из изображений с использованием Фурье-преобразования

Дополнительно, для улучшения информативности, были включены статистические признаки, такие как средняя яркость, минимум, максимум, медиана, стандартное отклонение, асимметрия, эксцесс и 19 квантилей с шагом 0.05. Также были рассчитаны площадь и периметр выделенной области изображения. Кроме того, для повышения качества извлеченных признаков, на изображение было применено 5 различных фильтров и преобразований, по каждому из которых собраны все перечисленные выше характеристики:

- Размытие по Гауссу — это процесс, при котором каждое значение пикселя изображения заменяется взвешенной средней значением соседних пикселей. Она позволяет уменьшить шум и сгладить градиенты. Для применения Гауссового размытия используется функция `cv2.GaussianBlur()`[15].
- Выравнивание гистограммы — это процесс изменения распределения яркости пикселей изображения так, чтобы его гистограмма (распределение интенсивностей) стала более равномерной. Выравнивание гистограммы повышает контраст тканей на снимке УЗИ, а

также снижает влияние артефактов. Для выравнивания гистограммы применялась функция `cv2.equalizeHist()`[16].

- Оператор Собеля — это фильтр для выделения границ в изображении, который использует вычисление градиента интенсивности пикселей. Оператор Собеля применяется для выделения горизонтальных и вертикальных границ. Для применения оператора Собеля используется функция `cv2.Sobel()`[17].
- Оператор Лапласа — это фильтр для выделения резких изменений в изображении, который вычисляет второй производный градиент интенсивности, он помогает выявить области, где происходит наибольшее изменение интенсивности. Вычислялся с помощью `cv2.Laplacian()` [18].
- Оператор Кэнни — это многоступенчатый алгоритм для детектирования границ в изображении. Оператор Кэнни был вычислен с помощью `cv.Canny()`[19].

Таким образом, для дальнейшего этапа классификации с каждого изображения было извлечено в сумме $68 * 6 + 70 = 478$ признаков.

4.3. Отбор и обработка признаков

В связи с тем, что в наборе данных было 478 признаков и 301 изображение, количество признаков оказалось слишком большим, а классификация с использованием такого числа признаков дала неудовлетворительные результаты. Поэтому было принято решение о снижении размерности пространства признаков. Для этой цели были проведены два типа анализа: корреляционный и регрессионный.

В рамках корреляционного анализа была рассчитана корреляция каждого признака с целевой переменной с использованием функции `pandas.corr()`. На основе полученных результатов были отобраны 30 наиболее коррелирующих признаков, которые предполагались наиболее информативными для дальнейшего анализа.

Для регрессионного анализа был применен метод главных компонент (PCA, Principal Component Analysis), метод линейного снижения размерности, который находит новые оси (главные компоненты) данных, упорядочивает их по убыванию важности и использует только наиболее значимые компоненты для анализа, сохраняя как можно больше информации о данных. Для дальнейшей классификации были выбраны 30 наиболее значимых главных компонент, которые обеспечивали сохранение большей части вариативности данных, тем самым снижая размерность и улучшая качество последующей классификации. Для применения метода главных компонент использовалась функция `sklearn.PCA.fit_transform()`.

5. Эксперимент

5.1. Дизайн эксперимента

Оценим результаты распознавания, полученные с использованием выбранных алгоритмов классификации, а также проведем сравнительный анализ эффективности корреляционного и регрессионного методов для выделения значимых признаков.

5.2. Условия эксперимента

Версии библиотек и инструментов:

- Python — 3.12
- OpenCV — 4.10.0.84
- Scikit-learn — 1.5.2
- Pandas — 2.2.3
- NumPy — 1.26.4
- SciPy — 1.14.1

Выборка была распределена на тренировочную и тестовую в соотношении 10:3. Размер выборок:

- Тренировочная — 210
- Тестовая — 91

5.3. Исследовательские вопросы

RQ1 : какой из выбранных алгоритмов лучше всего справляется с задачей классификации поражений щитовидной железы?

RQ2 : какой из применяемых методов понижения размерности лучше справился с выделением более значимых признаков?

RQ3 : применима ли ансамблевая модель из трех классификаторов Random Forest, SVM, Gradient Boosting on Decision Trees для моей задачи?

5.4. Метрики



Для сравнения алгоритмов классификации и методов понижения размерности были выбраны метрики:

- Accuracy.
- Recall.
- F1-мера.

Для задачи классификации поражений щитовидной железы критически важно минимизировать количество пропущенных пораженных снимков, то есть свести к минимуму количество ложных отрицательных ошибок (False Negative). В связи с этим в качестве одной из основных метрик была выбрана recall. Однако для предотвращения ситуации, при которой классификаторы, стремясь максимизировать recall, будут классифицировать все изображения как относящиеся к положительному классу, была также рассчитана F1-мера, которая учитывает как полноту, так и точность классификации.

5.5. Результаты

По результатам эксперимента было установлено, что наилучшие результаты по всем метрикам демонстрирует алгоритм Random Forest, использованный в сочетании с регрессионным анализом. Также удовлетворительные результаты были получены с использованием метода опорных векторов при применении корреляционного анализа.



Ансамблевая модель, построенная на основе трех классификаторов: SVM, Random Forest и Gradient Boosting на деревьях решений, продемонстрировала следующие результаты:

- Accuracy — 0.68
- Recall — 0.95
- F1-score — 0.78

5.5.1. RQ1

Лучшие результаты на используемом наборе данных показал Random Forest при применении регрессионного анализа, но SVM при применении корреляционного анализа также показал хорошие результаты.

5.5.2. RQ2

По полученным результатам нет явной разницы между применением регрессионного и корреляционного анализа.

5.6. RQ3

По результатам эксперимента можно сделать вывод, что ансамблевая модель применима для подобных задач.

5.7. Обсуждение результатов

Можно предположить, что результаты алгоритма Random Forest обусловлены тем, что на снимках УЗИ присутствует значительное количество шума и артефактов, с которыми данный метод эффективно справляется. Это предположение также подтверждается сравнительно низкими результатами метода опорных векторов (SVM), который известен своей чувствительностью к шуму и выбросам в данных. Однако следует отметить, что данный набор данных может быть сильно зашумлен, что является отклонением от стандартных характеристик подобных наборов, и это также могло повлиять на результаты классификации.

5.8. Угрозы нарушения корректности

Полученные результаты могут быть некорректными по следующим причинам:

1. рассматриваемый датасет был сильно зашумлен;
2. разное распределение в тестовом и тренировочном наборе данных;
3. обученные модели переобучились.

В ходе эксперимента были приняты меры для минимизации влияния второго фактора. Данные были случайным образом перемешаны, а затем разделены на тестовую и тренировочную выборки таким образом, чтобы в каждом наборе сохранялось одинаковое соотношение положительных и отрицательных примеров.

Для предотвращения переобучения была изначально отложена тестовая выборка, и модель имела доступ к ней только один раз в ходе эксперимента, что исключало использование информации из тестовой выборки при обучении модели. Кроме того, для повышения устойчивости к переобучению использовались методы машинного обучения, обладающие свойствами регуляризации.

Заключение

В ходе данной работы были выполнены следующие задачи:

- Был проведен анализ предметной области и выбрано 5 методов для проведения эксперимента.
- Осуществлен сбор признаков.
- Было проведено сравнение¹выбранных алгоритмов, в котором лучше всего себя показал Random Forest.
- Выбрано три метода для дальнейшей работы, а именно Random Forest, SVM, Gradient Boosting

В следующем семестре планируется реализация медицинского инструмента на базе проведенных исследований

- Улучшить процесс подбора гиперпараметров.
- Собирать более информативные признаки.
- Исследовать подходы глубокого обучения.

¹<https://github.com/ArtemKushnir/ClassificationThyroidDiseasesByUltrasoundImage>

Список литературы

- [1] Automatic Classification of Nodules from 2D Ultrasound Images Using Deep Learning Networks / Tewele W Tareke, Sarah Leclerc, Catherine Vuillemin et al. // Journal of Imaging. — 2024. — Vol. 10, no. 8. — P. 203.
- [2] Bharti Puja, Mittal Deepti, Ananthasivan Rupa. Preliminary study of chronic liver classification on ultrasound images using an ensemble model // Ultrasonic imaging. — 2018. — Vol. 40, no. 6. — P. 357–379.
- [3] Chaudhary Vikas, Bano Shahina. Imaging of the thyroid: Recent advances // Indian journal of endocrinology and metabolism. — 2012. — Vol. 16, no. 3. — P. 371–376.
- [4] Clinical practice guidelines for acute and chronic thyroiditis (excluding autoimmune thyroiditis) / EA Troshina, EA Panfilova, MS Mikhina et al. // Problems of Endocrinology. — 2021. — Vol. 67, no. 2. — P. 57–83.
- [5] Computer-aided diagnosis for classifying benign versus malignant thyroid nodules based on ultrasound images: a comparison with radiologist-based assessments / Yongjun Chang, Anjan Kumar Paul, Namkug Kim et al. // Medical physics. — 2016. — Vol. 43, no. 1. — P. 554–567.
- [6] DASMEHDIXTR. Edison AI. — 2021. — Accessed: 2024-12-15. URL: <https://www.kaggle.com/datasets/dasmehdixtr/ddti-thyroid-ultrasound-images>.
- [7] Deep convolutional neural networks in thyroid disease detection: a multi-classification comparison by ultrasonography and computed tomography / Xinyu Zhang, Vincent CS Lee, Jia Rong et al. // Computer Methods and Programs in Biomedicine. — 2022. — Vol. 220. — P. 106823.

- [8] Healthcare GE. Edison AI. — 2024. — Accessed: 2024-11-16. URL: <https://www.gehealthcare.com/middle-east/products/healthcare-it/open-ai-orchestrator>.
- [9] Horng Ming-Huwi. Multi-class support vector machine for classification of the ultrasonic images of supraspinatus // Expert Systems with Applications. — 2009. — Vol. 36, no. 4. — P. 8124–8133.
- [10] Jerbi Feres, Aboudi Noura, Khelifa Nawres. Automatic classification of ultrasound thyroids images using vision transformers and generative adversarial networks // Scientific African. — 2023. — Vol. 20. — P. e01679.
- [11] Lower thyroid cancer mortality in patients detected by screening: a meta-analysis / Shinje Moon, Young Shin Song, Kyong Yeun Jung et al. // Endocrinology and Metabolism. — 2023. — Vol. 38, no. 1. — P. 93–103.
- [12] NVIDIA. Monai. — 2024. — Accessed: 2024-11-16. URL: <https://monai.io/>.
- [13] OpenCV. — URL: https://docs.opencv.org/4.x/d7/d4d/tutorial_py_thresholding.html.
- [14] OpenCV. — URL: https://docs.opencv.org/4.x/df/d0d/tutorial_find_contours.html.
- [15] OpenCV. — URL: https://docs.opencv.org/4.x/d4/d13/tutorial_py_filtering.html.
- [16] OpenCV. — URL: https://docs.opencv.org/3.4/d4/d1b/tutorial_histogram_equalization.html.
- [17] OpenCV. — URL: https://docs.opencv.org/3.4/d2/d2c/tutorial_sobel_derivatives.html.
- [18] OpenCV. — URL: https://docs.opencv.org/3.4/d5/db5/tutorial_laplace_operator.html.

- [19] OpenCV. — URL: https://docs.opencv.org/4.x/da/d22/tutorial_py_canny.html.
- [20] Thyroid Nodule Characterization: Overview and State of the Art of Diagnosis with Recent Developments, from Imaging to Molecular Diagnosis and Artificial Intelligence / Emanuele David, Hektor Grazhdani, Giuliana Tattaresu et al. // Biomedicines. — 2024. — Vol. 12, no. 8. — P. 1676.
- [21] Vafaezadeh Majid, Behnam Hamid, Gifani Parisa. Ultrasound Image Analysis with Vision Transformers // Diagnostics. — 2024. — Vol. 14, no. 5. — P. 542.
- [22] Трошина ЕА, Платонова НМ, Панфилова ЕА. Динамика эпидемиологических показателей тиреоидной патологии у населения Российской Федерации: аналитический отчёт за период 2009-2018 гг // Проблемы эндокринологии. — 2021. — Vol. 67, no. 2. — P. 10–19.