

Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение
высшего образования
«Казанский (Приволжский) федеральный университет»

ИНСТИТУТ ФИЗИКИ
КАФЕДРА МЕДИЦИНСКАЯ ФИЗИКИ

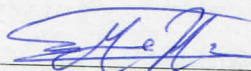
Направление 03.04.02 Физика
Направленность (профиль) подготовки: Медицинская физика

(магистерская диссертация)

**Количественные методы анализа магнитно-
резонансных томографических данных**

Студент 2 курса группы 06-119

«14» Июня 2023г



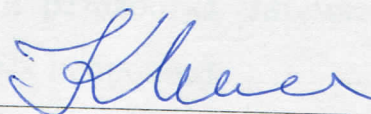
подпись

(Алхабеев М. Х.)

Научный руководитель.

д.ф.-м.н., профессор

«14» Июня 2023г



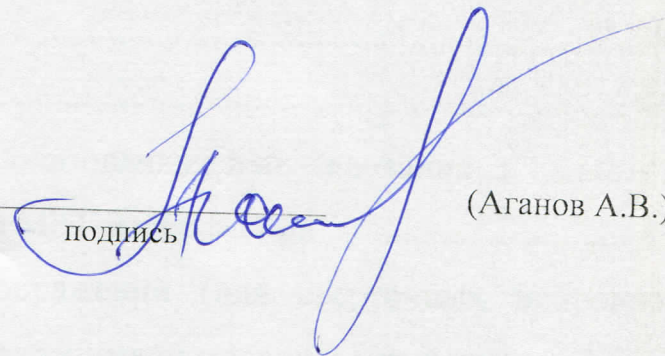
подпись

(Ильясов К.А.)

Зав. кафедрой

д.х.н., профессор

«14» Июня 2023 г



подпись

(Аганов А.В.)

Казань – 2023 г

Оглавление

Введение	4
Глава 1. Принципы магнитно-резонансной томографии	6
1.1 Физические принципы и общие характеристики магнитно резонансной томографии.	7
1.2 Физические основы МРТ, методы, преимущества и недостатки МРТ.....	9
1.2.1 Процесс визуализации	9
1.2.2 методы получения МР изображения	9
Глава 2. Сегментация данных резонансной томографии и методы диагностики	22
2.1 Сегментация изображений МРТ	22
2.1.1 Введение	22
2.1.2 Структуры глубокой нейронной сети	23
2.1.3 региональная сверточная сеть.	28
2.2 Методы детектирования позвонков на МРТ с помощью CNN ...	32
Глава 3. Проектирование и разработка математической модели анализа данных МРТ (для сверточных нейронов)	40
3.1 Подбор показателя математической модели и разработать модель для анализа данных МРТ.	40
3.1.1 Введение	40
3.1.2 МРТ данные использованные в исследования	42
3.2 Ручное сегментирование МРТ-изображений	43
3.3 Сегментация МРТ-изображений (для сверточных нейронов) программно на основе математической модели и сравнение с ручным методом	46

3.3.1	Разработка алгоритма сегментации позвонков на основе глубокого обучения	46
3.3.2	Разработка алгоритма определения клиновидности тел позвонков.	49
3.4	Анализ результатов	51
3.4.1	Результаты тестирования сети на тестовых данных	51
3.4.2	Разработка ПО для автоматизации сегментации и анализа МРТ-изображений позвоночника	54
3.5	Инструкция по использованию программы «LumbarSegmentor».....	55
	Заключение	60
	Благодарность	61
	Список литературы	62

Введение

Магнитно-резонансная томография или МРТ — это современный диагностический метод, позволяющий неинвазивно визуализировать строение тела. МРТ основано на явлении ядерного магнитного резонанса и позволяет неинвазивно получать двух- и трехмерные изображения живых объектов не причиняя им вреда и не используя ионизирующее излучение. Контраст МРТ изображений можно достаточно сильно менять за счет изменения параметров измерения, что делает МРТ один из ведущих методов медицинской диагностики. С другой стороны, в клинической МРТ до сих пор преобладает «визуальной» метод анализа изображений, на предмет наличия или отсутствия тех или иных анатомических структур, а точная количественная обработка размеров и объемов тех или иных органов или новообразований используется достаточно мало, ввиду их большей трудоемкости, по сравнению с визуальным контролем «выглядит нормально» / «обнаружено отклонение от нормальной анатомии». Однако, точный количественный анализ характерных размеров или объемов тех или иных структур может позволить выявить начало патологического процесса до момента его проявления в виде явного анатомического изменения. Так, например, уменьшение высоты позвонков часто говорит о начинающемся процессе остеопороза, однако детальная количественная обработка соответствующих изображений многократно увеличивает время их анализа и не делается врачами ввиду их перегруженности.

Цель данной работы состояла в разработке методов для автоматизации распознавания тех или иных анатомических структур на МРТ изображения и расчете их соответствующих количественных характеристик. В связи с этим была поставлена задача создания

программных средств для автоматического выделения позвонков на МРТ изображения и расчета их характерных размеров.

ГЛАВА 1. ПРИНЦИПЫ МАГНИТНО-РЕЗОНАНСНОЙ ТОМОГРАФИИ

Магнитно-резонансная томография (МРТ) — это медицинский процесс визуализации, в котором используются магнитное поле и радиочастотные (РЧ) сигналы для получения изображений анатомических структур. МРТ дает изображения, которые заметно отличаются от изображений, получаемых другими методами визуализации. Основное отличие заключается в том, что процесс МРТ может выборочно отображать несколько различных характеристик ткани. Потенциальное преимущество этого в том, что если патологический процесс не изменяет одну характеристику ткани и не создает контраст, он может быть виден на изображении из-за его влияния на другие характеристики. Это приводит к тому, что интерпретация данных МРТ несколько сложнее, чем для большинства методов визуализации. Чтобы оптимизировать процедуру МРТ для конкретного клинического обследования, пользователь должен хорошо знать характеристики магнитно-резонансного (МР) изображения и способы управления этими характеристиками.

МРТ-изображение отображает определенные физические характеристики ткани. Источником сигналов является состояние намагниченности, возникающее в ткани при помещении пациента в сильное магнитное поле. Намагниченность ткани зависит от наличия магнитных ядер. Конкретные физические характеристики ткани или жидкости, видимые на изображении, зависят от того, как изменяется магнитное поле в процессе получения изображения.

МРТ также может предоставить определенную химическую информацию, применяя спектроскопический анализ к радиочастотным сигналам, излучаемым тканью.

1.1 Физические принципы и общие характеристики магнитно-резонансной томографии.

1) Изображения плотности протонов (PD)

Наиболее прямой характеристикой ткани, которую можно визуализировать, является концентрация или плотность протонов (водорода). В изображении плотности протонов намагниченность ткани, интенсивность ЯМР сигнала и яркость изображения на МРТ определяются содержанием протонов (водорода) в ткани. Ткани, богатые протонами, производят больше сигнала и имеют яркий внешний вид [1].

2) Время магнитной релаксации — изображения T1 и T2

Время релаксации можно использовать для различения (то есть создания контраста) нормальных и патологических тканей. Каждая ткань характеризуется двумя временами релаксации: T1 и T2. Можно создавать изображения, в которых одна из этих двух характеристик является преобладающим источником контраста. Обычно невозможно создать изображения, в которых одна из характеристик ткани (например, PD, T1 или T2) является единственным чистым источником контраста. Как правило, происходит смешивание контраста, но изображение будет иметь больший вес по одной из них. Когда изображение описывается как T1-взвешенное изображение, это означает, что T1 является преобладающим источником контраста, но также возможно некоторое загрязнение от характеристик PD и T2 [1].

- **MR изображение**

МРТ-изображение может отображать различные характеристики тканей и жидкостей организма.




Рисунок 1 – Физические характеристики, формирующие связь между изображением и тремя характеристиками ткани [1]

- **Поле B_0**

Источником статического магнитного поля B_0 является магнит, достаточно большой для того, чтобы человек мог расположиться в его однородной части. Важнейшим свойством является напряженность магнитного поля B_0 . Желательна высокая напряженность магнитного поля B_0 , поскольку в ростом B_0 растет и сигнал ЯМТ, соответственно становится выше сигналы на МРТ изображениях. Для B_0 более 0.4 Тл требуется сверхпроводящий магнит.

Помимо номинальной напряженности поля B_0 , необходимо учитывать однородность этого поля по объему изображения. Неоднородность B_0 , составляющая всего несколько частей на миллион (ppm), приводит к заметному затемнению МР-изображений, а большие неоднородности вызывают пространственные искажения изображений.

Ясно, что большая часть преимуществ высокой напряженности поля может быть утеряна без достаточной однородности. Однородность B_0 оптимизируется с помощью процедуры, известной как «шимминг». Здесь магнит оснащен набором электромагнитных катушек. Тщательно регулируя величину тока в каждой из этих катушек, поле B_0 в объеме изображения регулируется или формируется до тех пор, пока не будет достигнута приемлемая однородность.

1.2 Физические основы МРТ, методы, преимущества и недостатки МРТ

1.2.1 Процесс визуализации

Процесс МР-томографии состоит из двух основных функций. Первый — получение РЧ-сигналов от тела пациента, а второй — математическая реконструкция изображения из полученных сигналов [1].

1.2.2 Методы получения МР изображения

Существует несколько основных методов визуализации, которые можно использовать для создания МР-изображений. Принципиальное различие между этими методами заключается в последовательности применения радиочастотных импульсов и градиентов в процессе сбора данных.

Поэтому разные методы часто называют разными импульсными последовательностями. Обзор наиболее распространенных методов показан на рис. 2. Для каждого метода визуализации существует набор параметров измерения, которые необходимо настроить для получения конкретных характеристик изображения. Выбор конкретного метода визуализации и значений коэффициентов обычно основывается на требованиях к

контрастной чувствительности к конкретной характеристике ткани (PD, T1, T2) и скорости сбора данных [1]. Однако другие характеристики, такие как визуальный шум и чувствительность к определенным артефактам, могут варьироваться от метода к методу. Все методы визуализации принадлежат к одному или обоим из двух основных семейств: спин-эхо или градиентное эхо. Разница между этими двумя семействами методов заключается в процессе, который используется для создания эхо-события в конце каждого цикла визуализации. Для методов спинового эха эхо-событие создается путем применения 180-градусного РЧ-импульса. Для методов градиентного эха измеряемый сигнал создается путем применения серии градиентов магнитного поля. Каждый метод имеет свои специфические характеристики и области применения.

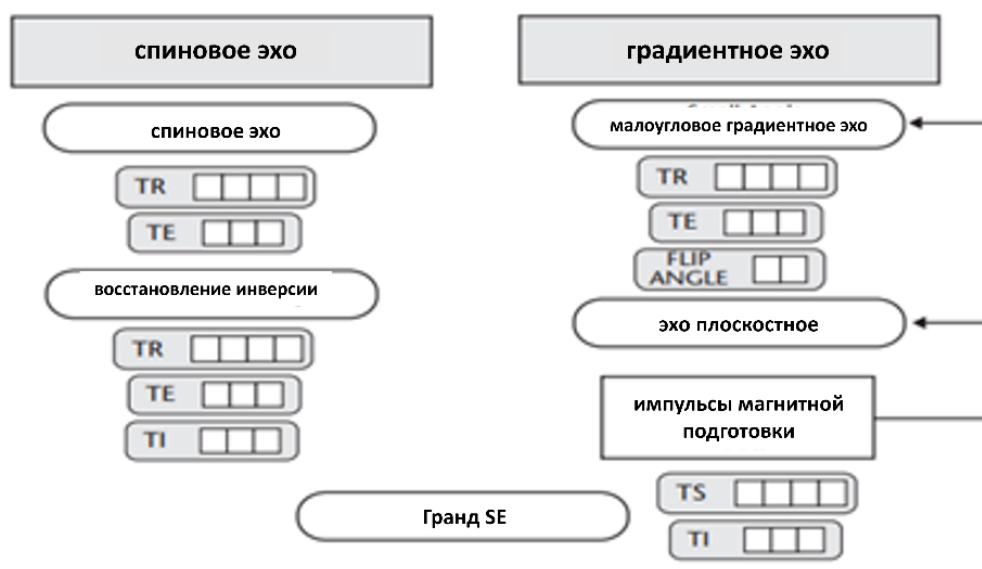


Рисунок 2 – Основные методы визуализации спинового эха и градиентного эха. GR and SE или GRASE представляет собой комбинацию двух методов

[1]

1) Методы визуализации спинного эха

Спиновое эхо — это название последовательности в которой используются РЧ-импульсы для создания эхо-сигналов.

Распад поперечной намагниченности (т. е. релаксация) происходит из-за расфазировки между отдельными ядрами. Как известно, для поперечной намагниченности необходимы два основных условия [1]:

- (1) Магнитные моменты ядер должны быть ориентированы в поперечном направлении, или плоскости.
- (2) Большинство моментов должно быть направлено в одном направлении внутри поперечная плоскость. Когда спин ядра имеет поперечную ориентацию, он на самом деле прецессирует или вращается вокруг оси, параллельной магнитному полю.

После приложения 90-градусного импульса возбуждения ядра имеют поперечную ориентацию и прецессируют вместе или синфазно вокруг оси магнитного поля. Однако внутри отдельного вокселя некоторые ядра прецессируют или вращаются быстрее, чем другие. Через короткий промежуток времени ядра уже не вращаются в одной фазе. По мере того, как направления ядер начинают раздвигаться, намагниченность ткани уменьшается. Через короткое время ядра беспорядочно ориентируются в поперечной плоскости; поперечная намагниченность пропадает. Существуют два фактора, которые способствуют расфазировке ядер и результирующей поперечной релаксации, теперь будут снова рассмотрены здесь. Одним из них является спин-спиновые взаимодействия, который приводит к относительно медленной дефазировке и потере намагниченности. Скорость, с которой это происходит, определяется характеристиками ткани. Именно эта дефазирующая активность характеризуется значениями T2 и источником контраста, который мы хотим получить на изображениях T2.

Вторым фактором, вызывающим относительно быструю расфазировку ядер и потерю поперечной намагниченности, является неоднородность магнитного поля [1]. Даже в небольшом объеме ткани неоднородности поля достаточны для быстрой дефазировки. Этот эффект, обычно не связанный с T2-характеристиками ткани, имеет тенденцию маскировать истинные релаксационные характеристики ткани. Другими словами, фактическая поперечная намагниченность релаксирует намного быстрее, чем это можно было бы предположить по характеристикам ткани. Напомним, что это время релаксации обозначено как T2*. Значение T2* всегда меньше значения истинное T2 ткани. В результате поперечная намагниченность может исчезнуть до того, как может сформироваться T2-контраст. Однако спиновое эхо позволяет восстановить утраченную когерентность фаз спингов в поперечной плоскости. Импульсная последовательность спинового эха показана на рис. 3. Поперечная намагниченность создается с помощью 90-градусного радиочастотного импульса возбуждения [1], который переворачивает продольную намагниченность в поперечную плоскость. Однако из-за локальной неоднородности магнитного поля в каждом вокселе протоны прецессируют с разной скоростью и быстро теряют когерентность. Это приводит к быстрому затуханию, характеризующемуся T2* и связанному с ним сигналу FID.

Если приложить 180-градусный импульс, он перевернет фазы прециссии спинов в поперечной плоскости. Это приводит к тому, что «быстрые» протоны располагаются позади более «медленных». Когда более «быстрые» протоны догонят более «медленные», их фазы совпадут и сформируется эхо-сигнал. Это вызовет повторное появление поперечной намагниченности. Однако она не возрастет до исходного значения, так как релаксация (расфазировка), производимая тканью, необратима.

Перефазировка протонов приводит к увеличению намагниченности до уровня, определяемого T2-характеристиками ткани [1].




Рисунок 3 – Процесс спинового эха, показывающий использование 180-градусного импульса для перефазировки протонов и создания эхо-события [1]

Затем другой 180-градусный импульс можно использовать для повторной перефазировки - это делается при мультиэхо-визуализации [1].

- **Контраст плотности протонов (PD)**

Контраст по плотности протонов проявляется по мере приближения продольной намагниченности к своему максимуму, который определяется временем T1 каждой конкретной ткани. Следовательно, для создания изображения по ПП требуются относительно длинные значения TR. Короткие значения TE обычно используются для уменьшения вклада контраста по T2 и для поддержания относительно высокой интенсивности сигнала [1].

- **Контраст T1**

Чтобы получить контраст изображения на основе различий T1 между тканями, необходимо использовать относительно короткие значения TR [1].

Второй фактор заключается в сохранении контраста T1 во время поперечной релаксации, для этого необходимы короткие значения TE [1].

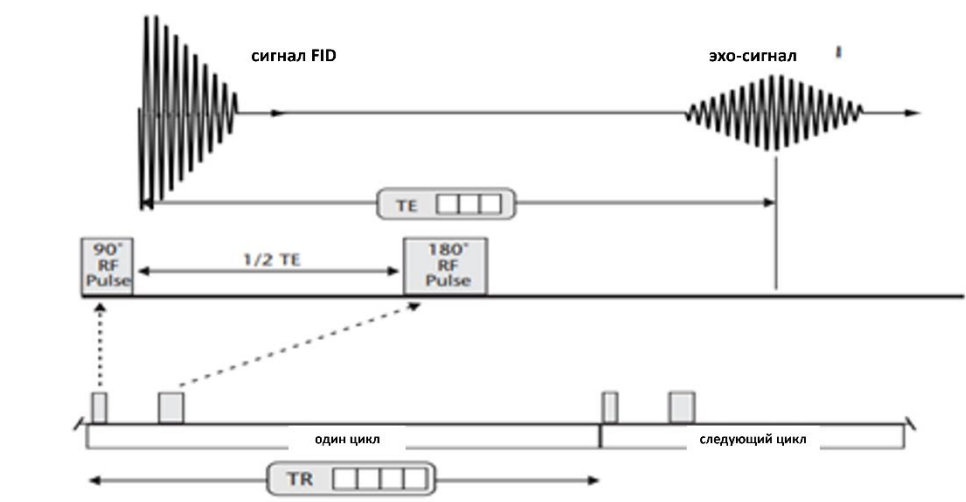


Рисунок 4 – РЧ-импульсы и временные интервалы в цикле визуализации спинового эха [1]

- **Контраст T2**

Для создания изображения со значительным контрастом T2 необходим выбор относительно длинного значения TR. Это сводит к минимуму влияние контраста по T1. Затем используются длинные значения TE, чтобы дать время контраста T2 развиваться. Методы спинового эха позволяют устранять эффект T2* и давать истинный контраст T2.

- **Множественное спиновое эхо**

Как показано на рис. 5, за один цикл можно создать серию эхо-событий. Это делается путем подачи нескольких 180-градусных импульсов после каждого 90-градусного импульса возбуждения. Преимущество состоит в том, что эхо-события с разными значениями TE создаются за один цикл сбора данных. Для каждого значения TE формируются отдельные

изображения. Это позволяет создавать как изображение PD (короткое TE), так и изображение T2 (длинное T2) в одном и той же серии измерений [1].




Рисунок 5 – Множественное спиновое эхо-изображение, которое дает изображение как PD, так и T2 в одном и том же захвате [1]

Основные типы изображений методом спинового эха. Оптимальные значения TR и TE для конкретного протокола могут варьироваться из-за учета других факторов, таких как время получения изображения, количество срезов и т. д [1].

- **Инверсионное восстановление**

Инверсионное восстановление - это метод визуализации спинового эха, используемый для нескольких конкретных целей. Одно приложение предназначено для получения высокого уровня контраста T1, а второе приложение — для подавления сигналов и, как следствие, яркости жира и жидкостей. Последовательность импульсов восстановления инверсии получается путем добавления дополнительного 180-градусного импульса к обычной последовательности спинового эха, как показано на рисунке 8.

Импульс добавляется в начале каждого цикла, когда он применяется к продольной намагниченности, перенесенной из предыдущего цикла. Каждый цикл начинается с того, что 180-градусный импульс меняет направление продольной намагниченности на противоположное. Нарастание (восстановление) намагниченности начинается с отрицательного (инвертированного) значения [1], а не с нуля, как в методе спинового эха. Метод инверсионного восстановления, как и метод спинового эха, использует 90-градусный импульс возбуждения для создания поперечной намагниченности и окончательный 180-градусный импульс для создания сигнала спинового эха. Вот почему он классифицируется как один из методов спинового эха, а не градиентного эха. Дополнительный временной интервал связан с последовательностью импульсов восстановления инверсии. Время между начальным 180-градусным импульсом и 90-градусным импульсом обозначается как время после инверсии (TI). Он может изменяться оператором и использоваться в качестве регулятора контрастности [1].




Рисунок 6 – Инверсионный метод восстановления с установленным значением TI позволяет получить изображение с высокой контрастностью

T1 [1]

2) Методы визуализации градиентного эха

Можно создать эхо-событие без 180-градусного РЧ-импульса, а применяя только градиенты магнитного поля. Существует несколько методов визуализации, в которых используется метод градиентного эха для получения РЧ-сигналов, и они составляют семейство методов градиентного эха. Основное преимущество методов градиентного эха перед методами спинового эха заключается в том, что методы градиентного эха обеспечивают более быстрое получение изображения. Методы градиентного эха обычно считаются одними из самых быстрых методов визуализации. Они также используются в некоторых ангиографических приложениях, поскольку градиентное эхо обычно дает яркую кровь, а также для функциональной визуализации. Одним из недостатков методов градиентного эха является то, что они не дают хороших T2-взвешенных изображений. Однако, комбинируя методы градиентного и спинового эха, это ограничение можно преодолеть [1].

Поперечная намагниченность присутствует только тогда, когда достаточное количество протонов вращается синфазно в поперечной плоскости. В методе спинового эха используются РЧ-импульсы для перефазировки протонов после того, как они были расфазированы из-за неоднородностей магнитного поля и эффектов восприимчивости в тканевом вокселе [1]. В методе градиентного эха протоны сначала намеренно дефазировываются путем включения градиента, а затем рефазировываются путем изменения направления градиента на противоположное, как показано на рис. 7. Градиентное эхо может быть создано только при наличии поперечной намагниченности. Это может быть либо во время периода затухания свободной индукции (FID), либо во время события спинового эха. На рис. 7 градиентный эхо-сигнал создается во время FID.




Рисунок 7 – Процесс градиентного эхо-сигнала с использованием градиента магнитного поля для создания эхо-события во время FID [1]

- **Угол поворота импульса возбуждения/насыщения**

Задача импульса возбуждения/насыщения, применяемого в начале цикла визуализации, состоит в том, чтобы преобразовать или перевернуть продольную намагниченность в поперечную намагниченность. Когда используется 90° -градусный импульс, вся существующая продольная намагниченность преобразуется в поперечную намагниченность, как мы видели в методах спинового эха [1]. Импульс 90° уменьшает продольную намагниченность до нуля (т.е. до полного насыщения) в начале каждого цикла визуализации. Это означает, что необходимо использовать относительно длинный интервал TR, чтобы позволить продольной намагниченности восстановиться до полезного значения. Время, необходимое для релаксации или восстановления продольной намагниченности, является одним из основных факторов, определяющих время сбора данных. Эффект снижения TR при использовании 90° -градусных импульсов показан на рис. 8. По мере уменьшения значения TR продольная намагниченность увеличивается до более низкого значения, а величина поперечной намагниченности и интенсивность радиочастотного

сигнала, создаваемого каждым импульсом, уменьшаются. Снижение интенсивности сигнала приводит к увеличению шума изображения. Кроме того, использование коротких интервалов TR с 90-градусным импульсом (как при спиновом эхо) не может давать хороших PD или T2-взвешенных изображений. Один из подходов к снижению TR и увеличению скорости сбора данных без возникновения только что описанных недостатков заключается в использовании импульса с углом поворота менее 90°. Импульс с малым углом поворота преобразует только часть продольной намагниченности в поперечную намагниченность. Это означает, что продольная намагниченность не полностью разрушается или сводится к нулю (насыщается) импульсом, как показано на рисунке 9. Уменьшение угла поворота имеет два эффекта, которые следует рассматривать вместе. Эффект, который мы только что наблюдали, состоит в том, что продольная намагниченность не разрушается полностью и остается на относительно высоком уровне от цикла к циклу даже для коротких интервалов TR [1]. Это повысит интенсивность РЧ-сигнала по сравнению с использованием 90-градусных импульсов. Однако по мере уменьшения угла поворота меньшая часть продольной намагниченности преобразуется в поперечную намагниченность. Это приводит к снижению интенсивности сигнала. Результатом является сочетание этих двух эффектов. Это показано на рисунке 10. Здесь мы видим, что при увеличении угла поворота в диапазоне от 0 до 90° уровень продольной намагниченности в начале цикла уменьшается. С другой стороны, по мере увеличения угла увеличивается доля этой продольной намагниченности, которая преобразуется в поперечную намагниченность, и увеличивается интенсивность радиочастотного сигнала. Комбинация этих двух эффектов показана на рис. 11. Здесь мы видим, как изменение угла поворота влияет на интенсивность сигнала. Точная форма этой кривой зависит от конкретного значения T1 ткани и интервала TR.




Рисунок 8 – Влияние снижения TR на восстановление продольной намагниченности в течение цикла и результирующую интенсивность сигнала при использовании 90-градусных импульсов [1]




Рисунок 9 – Влияние использования импульсов с малым углом переворота на продольную намагниченность [1]




Рисунок 10 – Влияние угла поворота импульса на уровень как продольной, так и поперечной намагниченности после подачи импульса [1]

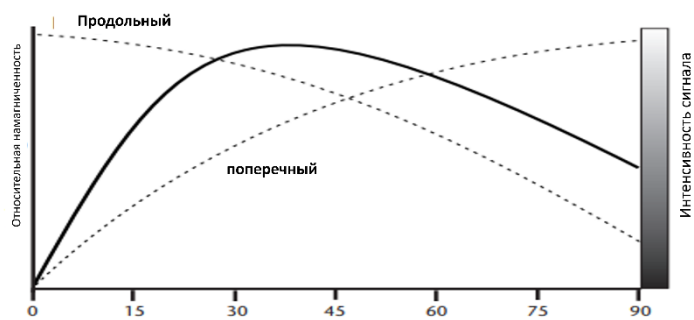


Рисунок 11 – Зависимость интенсивности сигнала от угла поворота [1]

ГЛАВА 2. СЕГМЕНТАЦИЯ ДАННЫХ РЕЗОНАНСНОЙ ТОМОГРАФИИ МЕТОДЫ ДИАГНОСТИКИ

2.1. Сегментация изображений МРТ

Сегментация изображения — это ветвь цифровой обработки изображений, имеющая многочисленные применения в области анализа изображений, дополненной реальности, машинного зрения и многих других. Таким образом, область анализа медицинских изображений растет, и сегментация органов, выявление заболеваний или аномалий на медицинских изображениях становится все более сложной задачей. Основная цель сегментации медицинских изображений контролировать рост таких заболеваний, как опухоль, контролировать дозировку лекарств и дозировку облучения. Сегментация медицинских изображений является действительно сложной задачей из-за различных артефактов, присутствующих в изображениях. В последнее время глубокие нейронные модели нашли применение в различных задачах сегментации изображений. Этот рост обусловлен достижениями и высокой эффективностью стратегий глубокого обучения. Обсужу различные используемые наборы данных медицинских изображений, различные показатели, используемые для оценки задач сегментации, и характеристики различных сетей на основе сверточной нейронной сети (далее CNN, англ. термин CNN - Convolutional neural network) [2,3].

2.1.1 Введение

Сегментация изображения включает в себя разделение входного изображения на разные сегменты с сильной корреляцией с интересующей

областью (ROI). Целью сегментации медицинских изображений является представление заданного входного изображения в обработанной форме для визуализации анатомических структур [1], определения области интереса (ROI), измерения объема ткани и измерения размера опухоли, помощи в определении дозы лекарства и планирования лечения до применения лучевой терапии или расчет дозы облучения [2].

2.1.2 Структуры глубокой нейронной сети

Наиболее важным подходом к искусственному интеллекту является глубокое обучение. Алгоритм глубокого обучения использует различные слои для построения искусственной нейронной сети. Искусственная нейронная сеть (ИНС) состоит из входного слоя, скрытого слоя (слоев) и выходного слоя [4].

Входной слой сети принимает сигнал, выходной слой принимает решение относительно входа, а между входным и выходным слоями есть скрытые слои, которые выполняют вычисления (показаны на рисунке 12). Глубокая нейронная сеть состоит из множества скрытых слоев между входным и выходным слоями. В этом разделе представлен обзор различных нейронных сетей глубокого обучения [2,5], используемых для задачи сегментации изображений. Различные структуры глубоких нейронных сетей, обычно используемые для сегментации изображений, можно сгруппировать, как показано на рисунке 13 [2].

1) Сверточная нейронная сеть.

Сверточная нейронная сеть или CNN считается одним из лучших алгоритмов для распознавания и классификации изображений. CNN состоит из стека из трех основных нейронных слоев (рис. 14):

- Сверточный слой

- Объединяющий слой
- Полносвязный слой

У каждого слоя своя роль. Слой свертки обнаруживает отдельные особенности, такие как края или другие визуальные элементы изображения. Слой свертки выполняет математическую операцию умножения локальных соседей пикселя изображения на ядра. CNN использует разные ядра для свертки данного изображения для создания своих карт функций. Эти слои объединяют различные реакции функций из данного входного изображения, чтобы обеспечить окончательные результаты. В литературе сообщалось о различных моделях CNN, включая AlexNet, GoogleNet, VGG, Inception, SqueezeNet и DenseNet. Здесь каждая сеть использует разное количество сверток и слоев пула с важными блоками процесса между ними. Модели CNN использовались в основном для задач классификации. В SqueezeNet и GoogleNet использовались для классификации изображений МРТ головного мозга по трем различным категориям. Производительность моделей сегментации CNN ограничена следующим [2,5]:

- Полносвязные слои в CNN не могут управлять различными входными размерами.
- Сверточная нейронная сеть с полносвязным слоем не может быть использована для задачи сегментации объектов, так как количество интересующих объектов в задаче сегментации изображения не фиксировано, поэтому длина выходного слоя не может быть постоянной [2].

Наиболее простым и популярным способом обучения является метод обучения с учителем (на маркированных данных) — метод обратного распространения ошибки и его модификации. Но существует также ряд техник обучения свёрточной сети без учителя. Например, фильтры операции свёртки можно обучить отдельно и автономно, подавая на них вырезанные случайным образом кусочки исходных изображений обучающей выборки и применяя для них любой известный алгоритм

обучения без учителя (например, автоассоциатор или даже метод k-средних) — такая техника известна под названием patch-based training. Соответственно, следующий слой свёртки сети будет обучаться на кусочках от уже обученного первого слоя сети. Также можно скомбинировать сверточную нейросеть с другими технологиями глубокого обучения. Например, сделать свёрточный авто-ассоциатор [6], свёрточную версию каскадных ограниченных машин Больцмана, обучающихся за счёт вероятностного математического аппарата [7], свёрточную версию разреженного кодирования (sparse coding), названную deconvolutional networks («развертывающими» сетями) [8].

- **Полностью сверточная сеть.**

В полностью сверточной сети (FCN) существуют только сверточные слои. Различные существующие в CNN архитектуры могут быть преобразованы в FCN путем преобразования последнего полностью связанного уровня CNN в полностью сверточный уровень. Модель, разработанная, может выводить карту пространственной сегментации и может иметь плотное попиксельное предсказание из входного изображения полного размера вместо выполнения предсказания по участкам [2,9].




Рисунок 12 – Модель искусственной нейронной сети (ИНС)[2]




Рисунок 13 – Различные типы архитектур глубоких нейронных сетей для сегментации изображений [2]




Рисунок 14 – Архитектура сверточной нейронной сети [2]

В FCN разрешение карт объектов, сгенерированных на выходе, снижается из-за распространения через альтернативные слои свертки и объединения. Это приводит к предсказаниям низкого разрешения в FCN с нечеткостью границ объектов. Сообщалось также о расширенном FCN под названием ParseNet; он использует глобальный средний пул для достижения глобального контекста. Также сообщалось о подходах, включающих

модели, такие как условные случайные поля и марковское случайное поле, в архитектуру DL [2].

2) Модели кодер-декодер

В моделях на основе кодера-декодера используется двухэтапная модель для отображения точек данных из входной области в выходную область. Этап кодировщика сжимает заданный ввод x до представления скрытого пространства, в то время как декодер прогнозирует вывод из этого представления. Различные типы моделей, основанных на кодировщиках-декодерах, обычно используемых для сегментации медицинских изображений, обсуждаются следующим образом [2,10]:

- **U-Net**

Модель U-Net имеет части с понижающей и повышающей дискретизацией. Секция понижающей дискретизации с архитектурой, подобной FCN, извлекает функции, используя свертки 3×3 для захвата контекста. Часть повышающей дискретизации выполняет деконволюцию, чтобы уменьшить количество вычисленных карт признаков. Карты признаков, созданные в результате субдискретизации или сжатия, подаются в качестве входных данных для повышающей дискретизации, чтобы избежать потери информации. Симметричная повышающая дискретизация обеспечивает точную локализацию. Модель генерирует карту сегментации, которая классифицирует каждый пиксель, присутствующий в изображении. Модель U-Net предлагает следующие преимущества:

Модель U-Net может выполнять эффективную сегментацию изображений, используя ограниченное количество помеченных обучающих изображений. Архитектура U-Net объединяет информацию о местоположении, полученную из пути с понижением дискретизации, и

контекстную информацию, полученную из пути с повышением дискретизации, для прогнозирования правильной карты сегментации [2,10]. Однако в средних слоях более глубоких моделей U-Net обучение обычно замедляется, из-за чего сеть игнорирует слои с абстрактными функциями. Для преодоления этих ограничений, в литературе были предложены различные варианты архитектуры U-Net: U-Net++, Attention U-Net и SD-U Net [2,10].

- **Виртуальная сеть**

Это также модель на основе FCN, используемая для сегментации медицинских изображений. Архитектура V Net состоит из двух частей:

- Компрессионная сеть.
- Декомпрессионная сеть.

Сеть сжатия содержит слои свертки на каждом этапе с функцией невязки. Эти слои свертки использовали объемные ядра.

Сеть декомпрессии извлекает признаки и расширяет пространственное представление карт признаков с низким разрешением. Он дает двухканальную вероятностную сегментацию как для переднего плана, так и для фона [2].

2.1.3 Региональная сверточная сеть

Региональная сверточная сеть использовалась для обнаружения объектов и задачи сегментации. Архитектура R-CNN, представленная в, генерирует сеть предложений регионов для ограничивающих рамок, используя процесс выборочного поиска. Эти предложения регионов затем преобразуются в стандартные квадраты и пересылаются в CNN, чтобы в качестве выходных данных генерировать карту векторов признаков.

Выходной плотный слой состоит из функций, извлеченных из изображения, и эти функции затем передаются в алгоритм классификации, чтобы классифицировать объекты, лежащие в сети предложений региона. Алгоритм также прогнозирует значения смещения для повышения уровня точности предложения области или ограничивающей рамки. Процессы, выполняемые в архитектуре R-CNN, показаны на рисунке 15. Использование базовой модели RCN ограничено из-за следующего [2,10]:

Его нельзя реализовать в режиме реального времени, так как для обучения сети задаче классификации 2000 предложений регионов на тестовом изображении требуется около 47 секунд. Алгоритм выборочного поиска является предварительно определенным алгоритмом. Следовательно, на этом этапе обучение не происходит. Это может привести к созданию неблагоприятных предложений регионов-кандидатов [2,10].

1) Быстрый R-CNN

В R-CNN предлагаемые области перекрытия изображений и одни и те же вычисления CNN выполняются снова и снова. Быстрая R-CNN, описанная в, получает входное изображение и набор предложений объектов. Затем CNN генерирует сверточные карты признаков. После этого слой объединения ROI преобразует каждое предложение объекта в вектор признаков фиксированного размера. Векторы признаков отправляются в последние полносвязные слои модели. В конце вычисленный вектор признаков области интереса передается на уровень softmax для прогнозирования значений класса и смещения предлагаемой области. Быстрый R-CNN медленнее из-за использования алгоритма выборочного поиска [2,11].

2) Быстрее R-CNN

В R-CNN и быстром R-CNN предлагаемые области были созданы с использованием процесса выборочного поиска и были медленным процессом. Поэтому в более быстрой архитектуре R-CNN, представленной [2,12], была развернута единая сверточная сеть для выполнения как предложений регионов, так и задачи классификации. В модели используется сеть региональных предложений (RPN), проходящая через скользящее окно в верхней части всей карты характеристик CNN. Для каждого окна выводятся к различным потенциальным граничным прямоугольникам с соответствующими оценками, представляющими положение объекта. Эти ограничивающие рамки, подаваемые на быстрый R-CNN, генерируют точные классификационные рамки.

3) Маска R-CNN.

Каймин Хэ и др [2,4], в расширен более быстрый R-CNN, чтобы представить Mask R-CNN, например, для сегментации. Модель может обнаруживать объекты на данном изображении и генерирует высококачественную маску сегментации для каждого объекта на изображении. Он использует слой ROI-Align для сохранения точного пространственного положения данного изображения. Сеть региональных предложений (RPN) сгенерировала несколько ROI с использованием CNN. Сеть ROI -Align генерирует несколько ограничивающих рамок, которые деформируются до фиксированных размеров. Искаженные объекты, вычисленные на предыдущем шаге, передаются на полносвязный слой, чтобы создать классификацию с использованием слоя softmax. Модель имеет три выходных ветви: одна ветвь вычисляет координаты ограничивающей рамки, вторая ветвь определяет связанные классы, а последняя ветвь оценивает двоичную маску для каждой области интереса.

Модель обучает все ветви совместно. Ограниченные прямоугольники улучшены за счет использования регрессионной модели. Классификатор маски выводит двоичную маску для каждой области интереса [2].




Рисунок 15 – Модификация Deeplabv3, в которой используется модуль объединения пространственных пирамид (а) со структурой кодер-декодер (б) Предлагаемая модель Deeplabv3+ содержит обширную семантическую информацию от модуля кодировщика, в то время как подробные границы объекта восстанавливаются с помощью простого, но эффективного модуля декодера [2]



Рисунок 16 – Архитектура R-CNN [2]

2.2 Методы детектирования позвонков на МРТ с помощью CNN

В анализе изображений позвоночника DL (Deep learning) широко применяется для сегментации, обнаружения, диагностики и количественной оценки. Он может использовать статическую или динамическую информацию об изображении, а также локальную или нелокальную информацию. Точность анализа DL была почти такой же высокой, как у врачей, а разница между DL и радиологов оказалось ниже, чем у других рентгенологов. Если эти автоматизированные методы можно систематически интегрировать в систему, то можно реализовать полностью автоматизированную обработку [2].

- **Методы глубокого обучения**

Ниже излагаются общие структуры нейронных сетей (рис. 17), используемые в анализе изображений позвоночника DL. Искусственный нейрон является основной единицей нейронных сетей (рис. 18.A). Он включает в себя входной вектор x , веса линейного преобразования w , смещение b и нелинейную функцию активации f , как показано в уравнении (1) [2,13]:

$$y = f(w^T x + b) \quad (1)$$

где y — выход, полученный 1 нейроном следующего слоя. Если следующий слой имеет несколько нейронов, выходной вектор

$$y = [y_1, \dots, y_M]^T$$

формируется в соответствии с

$$y = [f(w_1^T x + b_1), \dots, f(w_M^T x + b_M)]^T \quad (2)$$

который можно упростить как

$$y = f(w^T x + b) \quad (3)$$

Где $w = [w_1, \dots, w_M]^T$, $b = [b_1, \dots, b_M]^T$ а функция сигмовидной или выпрямленной линейной единицы (ReLU) обычно выбирается в качестве f . Эти нелинейные функции обеспечивают новое представление признаков с помощью нелинейных преобразований. Глубокие сети с прямой связью (DFN) (рис. 19.В) аппроксимируют некоторые сложные целевые функции множеством искусственных нейронов в цепной структуре, как показано в уравнении (4) [2,14]:

$$y = f(w_L^T f(w_{L-1}^T \dots f(w_1^T x + b_1) + b_{L-1}) + b_1) \quad (4)$$

Где L — длина цепи и дает глубину сети, которую также называют общим числом слоев. Прямая связь означает, что нет никаких обратных связей, в которых выходные данные модели возвращаются обратно в себя. Помимо выходного слоя, обучающие данные не дают желаемого результата других слоев, которые поэтому называются скрытыми слоями. Гудфеллоу и др. предложил рассматривать DFN как машины аппроксимации функций, предназначенные для статистического обобщения [2,14].

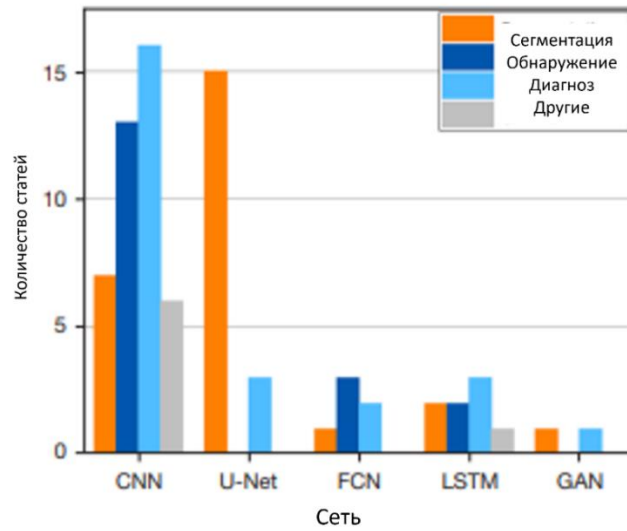


Рисунок 17 – Количество часто используемых сетевых структур при анализе изображений позвоночника DL [2,14]




Рисунок 18 – Глубокая сеть прямой связи с 5 слоями.

(A) Входной вектор $x = [x_1, \dots, x_M]$ и смещение b , взвешенная связь, состоящая из весового вектора $w = [w_1, \dots, w_M]^T$ и функции активации f . (B) Глубокая сеть прямой связи, состоящая из 1 входного слоя, 3 скрытых слоев и 1 выходного слоя [2,15]

DFNs являются основой для многих моделей DL. Сверточная нейронная сеть (CNN) — Одна из самых популярных сетей для анализа изображений позвоночника. Он состоит из слоев свертки, нелинейных слоев и слоев объединения (рис. 19.А). Поскольку нелинейный слой такой же, как и DFNs, следующее обсуждение сосредоточено на структурах и функциях двух других слоев. Сверточные слои CNN учитывают инвариантные статистические свойства перевода, разделяя весовые параметры в нескольких местах изображения. Матричное умножение $w^T x$ в уравнении (3) заменяется сверткой как минимум в 1 слое. Учитывая ядро свертки k , уравнение (3) переписывается как [2,13]:

$$y = f(k * x + b) \quad (5)$$

Где $*$ обозначает операцию свертки. Матричная форма уравнения (5) есть

$$y = f \left(\begin{pmatrix} k_1 & \dots & k_{S-1} & k_S & \dots & 0 & 0 \\ 0 & k_1 & \dots & k_{S-1} & k_S & \dots & 0 \\ 0 & 0 & k_1 & \dots & k_{S-1} & k_S & 0 \\ 0 & 0 & 0 & \ddots & \dots & k_{S-1} & k_S \\ 0 & 0 & 0 & 0 & k_1 & \dots & k_{S-1} \\ 0 & 0 & \dots & 0 & 0 & k_1 & \vdots \\ 0 & 0 & \dots & 0 & 0 & 0 & k_1 \end{pmatrix} x + b \right) \quad (6)$$

Где K_1, K_{S-1}, K_S — значения k . Меньший размер ядра S означает, что меньше входных нейронов подключено к следующему слою и более разреженная матрица W . Таким образом, CNN позволяет нейронным сетям с небольшим объемом памяти быть вычислительно эффективными. Для анализа позвоночника и изображение x , и ядро свертки k имеют двумерную (2D) форму. Слои объединения CNN заменяют каждый выход статистикой его ближайших выходов. Например, максимальное объединение и среднее объединение будут выводить максимальные и средние значения в пределах

прямоугольной окрестности. Операция объединения обеспечивает инвариантность к локальному переводу, что снижает чувствительность сетей к местоположению объекта. Используя огромное количество 2D- или 3D-изображений позвоночника в качестве входных данных и помеченные достоверные данные в качестве выходных данных, CNN демонстрирует большую способность изучать высокоуровневые функции и улучшать общую производительность сегментации и/или классификации изображений позвоночника [2,13].

U-Net представляет собой типичную CNN для сегментации изображений, которая имеет сокращающийся путь для дискретизации изображения вниз и расширенный путь для дискретизации изображения вверх (рис. 18.В). Путь сокращения состоит из слоев свертки и объединения, где пространственная информация изображения уменьшается, а функции высокого уровня извлекаются. В экспансивном пути пространственная информация объединяется с объектом из сокращающегося пути. Для задач сегментации позвоночника путем конкатенации получаются многомасштабные функции для увеличения контраста и уменьшения размытости границ между позвонками, МПД и фоном, что приводит к более точной сегментации позвоночника. Рекуррентная нейронная сеть (RNN) в первую очередь предназначена для данных последовательности обработка. Базовая структура RNN состоит из входных узлов, выходных узлов и скрытых узлов с циклическим соединением. Вычислительную графику можно получить, развернув эту рекурсивную структуру во времени, что приведет к совместному использованию параметров (рис. 19.А). Обычно RNN записывает информацию из предыдущего ввода в вектор состояния, который хранится в скрытых слоях. Токовый выход определяется не только текущим входом, но и вектором состояния. Однако распространение градиента на многих стадиях имеет тенденцию исчезать или взрываться.

Следовательно, эта структура не может долго удерживать информацию, особенно при увеличении длины контекста [2,13].




Рисунок 19 – Структура сети CNN и U-Net (U-Net — типичная сверточная нейронная сеть, она имеет сокращающийся путь для понижения дискретизации изображения и расширяющийся путь для повышения дискретизации изображения). (A) - CNN, (B) - U-Net [13]

Составные карты объектов представляют собой группу карт объектов, созданных предыдущим слоем свертки, нелинейным или объединяющим слоем. CNN, сверточные нейронные сети [2,13].




Рисунок 20 – Сетевые структуры RNN, модуля LSTM и GAN.

(A) RNN имеет входные узлы, выходные узлы и скрытые узлы с циклическим соединением. (B) Блок LSTM состоит из входных и выходных вентилей, которые построены слоями нейронной сети. Входной шлюз добавляет важную информацию к потоку данных и «забывает» неважные части. Выходной вентиль решает, какой модуль LSTM будет выводить. (C) Генератор GAN создает синтезированные изображения, а дискриминатор оценивает синтезированные изображения и истинные изображения [15]

Чтобы решить эту проблему, сеть краткосрочной долговременной памяти (LSTM) использует разные порты для управления потоком информации в блок LSTM или из него (рис. 20.B). Таким образом, LSTM

эффективно использует, сохраняющуюся в изображениях позвоночника, которая полезна для повышения точности обнаружения, 1 дискриминатора и 1 генератора, играемых в игре с нулевой суммой (рис. 20.С). Генератор создает выборки, в то время как дискриминатор пытается отличить выборки из обучающих данных от «фальшивых выборок» из генератора. Однако на практике обучение GAN затруднено генератора и дискриминатора. Для решения этой проблемы были предприняты значительные усилия. При сегментации позвоночника дискриминатор различает прогностические сегментные карты и базовые карты истинности, оценивая их. Затем оценка указывает генератору уменьшить задержку между картой предсказания и картой достоверности. Этот механизм может исправлять ошибки прогнозирования и преодолевать ограничения небольших наборов данных, тем самым повышая непрерывность данных на глобальном уровне [2,13].

ГЛАВА 3. ПРОЕКТИРОВАНИЕ И РАЗРАБОТКА МАТЕМАТИЧЕСКОЙ МОДЕЛИ АНАЛИЗА ДАННЫХ МРТ (ДЛЯ СВЕРТОЧНЫХ НЕЙРОНОВ)

3.1 Подбор показатели математической модели и разработать модель для анализа данных МРТ

3.1.1 Введение

В данной главе представлены результаты нашей разработки и реализации алгоритма сегментации поясничных позвонков позвоночника и определения степени их деформации посредством сверточных нейронов. Во-первых.

Автоматическая и точная классификация изображений МРТ позвоночника имеет большое значение для более точного медицинского анализа и интерпретации. За последнее десятилетие было предложено несколько подходов. Этот рабочий проект был сфокусирован на сегментации поясничного отдела позвоночника и определении типа и степени деформации позвонков при остеопорозе. Мы использовали МРТ изображения 200 пациентов (100 - внешне нормальный, без признаков патологии и 100 с явными признаками деформации позвонков) предоставленных нам клиникой "БАРСМЕД" в рамках научного сотрудничества.

В данной работе МРТ изображения от 200 пациентов были просегментированы вручную. Как правило, сегментация занимала 1 час на каждого пациента.

Все CNN, представленные в данной главе, были созданы на языке Python 3.8. Для определения степени деформации позвонка, нахождение

контура маски позвонка производилось с помощью алгоритма, встроенного в пакет openCV.

Реализованный в работе пакет программ, позволяет автоматизировать процесс количественной оценки наличия деформации позвонков, определения их типа (клиновидной или двояковогнутой), а также степени деформации (I-мягкая, II - умеренная и III -тяжёлая).

В основе алгоритма сегментации позвонков используется глубокая сверточная нейронная сеть Mask RCNN. Выбор такой архитектуры обусловлен тем, что требуется сегментировать несколько объектов (позвонков) на одном изображении. Для обучения и тестирования такой сети был использован набор данных, которые включал в себя изображения от 200-та пациентов (100 условно здоровых и 100 с наличием деформации). Для каждого пациента были сегментированы вручную несколько центральных срезов, данные ручной разметки использовались в качестве эталонных при обучении и тестировании нейронной сети.

Для автоматической оценки наличия деформация и определения ее типа и степени был разработан еще один алгоритм, который анализирует маски позвонков, отсегментированные нейронной сетью. Алгоритм позволяет автоматически определить форму позвонка, его центр масс, расстояние между соседними позвонками, а также соотношения сторон позвонка. На основе 4 рассчитанных параметров позвонка осуществляется оценка наличия деформации, и устанавливается тип и степень деформации. Существует 3 степени клиновидной деформации:

I – мягкая (20-25%)

II – умеренная (25-40%)

III – тяжелая (более 40%)

3.1.2 МРТ данные использованные в исследования

Наборы данных представляет собой T2-взвешенные МРТ изображения поясничного отдела позвоночника в сагиттальной и корональной проекциях в формате DICOM (Digital Imaging and Communications in Medicine). Для обучения и тестирования нейронной сети были выбраны и вручную отсегментированы 3-5 центральных среза на каждого пациента. Для расширения количества обучающих данных было принято решение использовать не только сагиттальные срезы, но и корональные. Ручная сегментация МРТ изображений производилась в программе MedSeg. Маски позвонков, отсегментированные на T2-взвешенных (TSE) МРТ изображениях поясничного отдела позвоночника представлены в формате NIFTI. Описание набора данных представлено в таблице 1. Пример сегментированных позвонков показан на рисунке 21.




Рисунок 21 – Пример сегментированных вручную позвонков

Таблица 1 – Описание набора данных

Количество пациентов :	120 (обучения)	50 (тестирования)	30 (валидации)
Здоровых (100)	70	20	10
Больных (100)	50	30	20
Плоскость	Сагиттальная / корональная		
Количество срезов	3-6 центральных срезов		
Изображений	1095	466	289
Аугментация: эластичная деформация	3286	-	
Импульсная последовательность	T2-взвешенными (TSE)		
Локализация позвонков	Поясничный отдел: L1-L5		

3.2 Ручное сегментирование МРТ-изображений

Первым шагом в достижении цели этой работы являлось получение достаточного количества размеченных МРТ-изображений поясничного отдела позвоночника.

На этом этапе изображения 200 субъектов были вручную сегментированы с помощью программного обеспечения (MedSeg). Все эти МРТ изображения были получены на 3 Тесла томографе Siemens 3T Verio. Сегментация выполнялась на (8-10) срезов для каждого пациента (4-5 срезов) коронарных и (4-5 срезов) сагиттальных. Использовались T2-взвешенные изображения, полученные TSE-последовательности импульсов. Протокол исследования был фиксирован и совпадал со стандартным протоколом клинических МРТ обследований позвоночника в клинике.

- **Программ MedSeg**

MedSeg – это название небольшой компания, расположенной в Осло, Норвегия. Она была основанная двумя радиологами в 2019 году. Компания разработала одноименный онлайн-инструмент для проведения анализа и сегментации изображений, полученных при КТ/МРТ. Программа создана на основе JavaScript и позволяет рентгенологам сегментировать рентгеновские изображения непосредственно в веб-браузере без необходимости загрузки, установки или регистрации программы [16].

- **Преимущества программы MedSeg:**

- Не требуется установка программы или регистрация. Работа может быть произведена непосредственно в браузере.
- Поддерживаемые форматы файлов: DICOM и NIfTI (в настоящее время загрузка масок поддерживается только для NifTI- Neuroimaging Informatics Technology Initiative).
- Простой запуск: файлы открываются путем простого перетаскивания в окно браузера.
- Быстрое и простое управление в процессе сегментации с помощью клавиатуры, созданной по мотивам игр.
- PACS-подобные элементы управления: управление с помощью мыши – масштабирование, панорамирование и изменение окна/центра.
- Ручная сегментация: подход на основе инструментов кисти, включая простое применение порогового выделения.
- Сегментация на основе искусственного интеллекта: использование ИИ-моделей непосредственно в инструменте для автоматического сегментирования интересующих областей файла.

- Полуавтоматическая сегментация на основе ИИ: интерактивные модели ИИ, реагирующие на нажатия мыши пользователя или предсказывающие следующий срез на основе сегментации текущего среза.
- Мгновенная объемная оценка на основе сегментации: одним щелчком мыши можно получить объем сегментации. Полезно как в клинической, так и в исследовательской практике.
- База данных: небольшая, но растущая открытая база данных изображений с необработанными изображениями и подключенными масками сегментации, свободная для загрузки.
- Сервис сегментации: пользователи также могут позволить команде MedSeg выполнить необходимую сегментацию (платная услуга).
- Разработка ИИ-моделей: пользователи также могут позволить команде MedSeg разработать ИИ-модели, подходящие для нужд пользователя (платная услуга).
- Проект построен на HTML5/JavaScript и использует TensorFlow.js для искусственного интеллекта [16].





Рисунок 22 – Интерфейс программы MedSeg



(А)

(Б)

Рисунок 23 – Иллюстрация процедур ручной сегментации и результатов.

(А) Первоначальная идентификация поясничной области.

(Б) Окончательная полученная бинарная маски

3.3. Сегментация МРТ-изображений (для сверточных нейронов) программно на основе математической модели и сравнение с ручным методом

3.3.1 Разработка алгоритма сегментации позвонков на основе глубокого обучения

На рисунке 24 показана общая методика анализа МРТ-изображений позвоночника и распознавания деформации позвонков. Данный подход включает в себя два алгоритма, а именно:

1. Нейросетевой алгоритм сегментации позвонков.
2. Алгоритм определения клиновидности тел позвонков




Рисунок 24 – Разработка алгоритма сегментация позвонков и определения их клиновидной деформации

1) Нейросетевой алгоритм сегментации позвонков.

Архитектура Mask-RCNN представлена на рисунке 25.




Рисунок 25 – Архитектура Mask-RCNN

2) Обучение нейронной сети Mask-RCNN

На рисунке 26 представлены графики процесса обучения и параллельной валидации нейронной сети Mask-RCNN. Графики

показывают динамику изменения ошибки сети на обучающей и валидационной (проверочной) выборках в течении 250 эпох обучения.




Рисунок 26 – График изменения ошибки обучения и валидации сети в течении 250 эпох : верхний- для обучающей выборки, нижний -для валидационной выборки.

3) Оценка качества сегментации нейронной сетью.

В качестве метрик для оценки качества сегментации, был выбран коэффициент Дайса (Dice coefficient) (коэффициент Сёренсена — Sorensen–Dice coefficient) [17].

Коэффициент Дайса (DSC) определяется следующей формулой:

$$Dice(X, Y) = \frac{2|X \cap Y|}{|X| + |Y|} \quad (7)$$

Где X является предсказанной, а Y - эталонной маской на текущем изображении. $|X|$ означает мощность множества X (количество элементов в этом множестве), а \cap – пересечение X и Y .

3.3.2 Разработка алгоритма определения клиновидности тел позвонков.

Для определения клиновидности тел позвонков необходимо определить параметры каждого позвонка, показанные на рисунке 27, а именно A , M , P .




Рисунок 27 – Сагиттальный вид позвонка




Рисунок 28 – Алгоритм определения клиновидности позвонков

Разработанный алгоритм определения клиновидности тел позвонков состоит в следующем:

- нахождение контура маски с помощью алгоритма, встроенного в пакет OpenCV.
- аппроксимация контура в виде прямоугольника и определения четырех вершин как показано на рисунке 29. Для этого используется встроенного в пакет openCV алгоритм Дугласа-Пекера, позволяющий уменьшить число точек кривой, аппроксимированной большей серией точек.




Рисунок 29 – Позвонки с наложенными вершинами и ребрами

- Определение центра масс позвонка и расчет параметров A , M , P (рис 28)
- Расчет соотношения A/P , M/P
- Определение типа клиновидной деформации
- Определение степени клиновидной деформации
- Определение межпозвоночное расстояние

3.4 Анализ результатов

3.4.1 Результаты тестирования сети на тестовых данных

Проводилась оценка сети отдельно на данных здоровых людей и на данных людей с диагностируемой деформацией позвонков. Распределение результатов оценки работы нейронной сети на данных людей с диагностируемой деформацией позвонков и для здоровых людей представлены на рисунках 30 и 31 соответственно.

Распределение результатов оценки работы нейронной сети на данных людей с диагностируемой деформацией позвонков представлено на рисунке 30.




Рисунок 30 – Распределение результатов оценки работы нейронной сети на МРТ данных пациентов с диагностируемой деформацией позвонков.




Рисунок 31 – Распределение результатов оценки работы нейронной сети на МРТ данных без признаков патологии.

В таблице 2 представлен количественный сравнительный анализ результатов сегментации позвонков с помощью обученной нейронной сети.

Таблица 2 – Статистические данные результатов тестирования алгоритма сегментации позвонков

Коэффициент Дайса (DSC)	Здоровые	Больные	Общее
Среднее \pm SD	0.938 \pm 0.045	0.932 \pm 0.043	0.934 \pm 0.044
Квантиль 0.25 %	0.94	0,93	0,93
Медиана	0.96	0.95	0.95
Квантиль 0.75 %	0.96	0.95	0.96

Поскольку на практике будут использоваться сагиттальные срезы для определения наличия в работе дополнительно оценивалось качество 15 сегментации нейронной сети на сагиттальных срезах позвоночника, как это показано на рисунке 32.




Рисунок 32 – Распределение результатов оценки работы нейронной сети на сагиттальных изображениях.

Результаты оценки качества нейронной сети на сагиттальных срезах сравнивались с результатами сегментации на корональных срезах (рис. 33).




Рисунок 33 – Распределение результатов оценки работы нейронной сети на корональных изображениях.

Сравнительный анализ показан в таблице 3.

Таблица 3 – Статистические данные результатов тестирования алгоритма сегментации позвонков

Коэффициент Дайса (DSC)	Корональные	Сагиттальные
Среднее \pm SD	0.933 \pm 0.038	0.936 \pm 0.046
Квантиль 0.25 %	0.93	0.94
Медиана	0,95	0,95
Квантиль 0.75 %	0,95	0.96

3.4.2 Разработка ПО для автоматизации сегментации и анализа МРТ-изображений позвоночника

Описанные выше алгоритмы были реализованы в программное обеспечение для автоматизации сегментации и анализа МРТ-изображений позвоночника.

Программа позволяет осуществлять следующее:

- загружать DICOM МРТ-изображений;
- автоматически сегментировать позвонки с помощью обученной нейронной сети;
- вычислять количественные параметры позвонков, а именно: высоты сторон каждого позвонка (передняя, срединная и задняя), высоту дисков и координаты центров масс каждого позвонка;
- оценить наличие или отсутствие деформации, оценить вид деформации (клиновидной и двояковогнутой) и ее степень.
- Сохранить результаты анализа как качественные (сегментированные позвонки и отмеченными параметрами), так и количественные значения.

3.5 Инструкция по использованию программы «LumbarSegmentor»

После запуска, программа имеет следующий вид




Рисунок 34 – Общий вид интерфейса

Интерфейс состоит из следующих трех областей:

1. Область управления:

Имеет 4 кнопки, названия которых содержит смысл их действия:

- load DICOM - позволяет выбрать файл с МРТ-изображением
- Segment – производит сегментацию позвонки
- Analysis – осуществляет расчет параметров позвонков
- Save results – сохраняет количественные результаты в таблице xlsx, а сегментированные изображения в виде png , jpg.




Рисунок 35 – Область управления

2. Область отображения изображения (IMAGE)




Рисунок 36 – Вид окна в исходном состоянии (слева) и после загрузки МРТ-изображения (справа)




Рисунок 37 – Вид после сегментации (слева) , после измерения параметров позвонков (справа)

3. Область отображения количественных результатов (RESULTS)




Рисунок 38 – Исходный вид

RESULTS							
№	Center	A, мм	M, мм	P, мм	Клин.%	Двояк.%	диск, мм
L1	(219, 45)	24	23	19	20.83	4.17	8.97
L2	(213, 81)	24	23	23	4.17	4.17	10.38
L3	(204, 119)	25	23	22	12.0	8.0	11.47
L4	(198, 159)	26	22	22	15.38	15.38	12.89
L5	(198, 198)	23	21	20	13.04	8.7	0

Рисунок 39 – Вид после отображения результатов измерения

- **Как загрузить МРТ-изображение?**

- нажать кнопку **load DICOM**
- найти папку где расположены МРТ-изображения
- выбрать файл и нажать «открыть»





Рисунок 40 – Как загрузить МРТ-изображение


- **Как сохранить результаты?**

- Нажать на кнопку «Save results»
- Выбрать путь куда сохранить
- Задать имя файла
- Нажать сохранить


В результате сохранится **количественные результаты в таблице xlsx**, а **сегментированные изображения в виде *.png , *.jpg**.



П.П.П.xlsx



П.П.П.jpg



П.П.П.png

Рисунок 41 – Сохраненные результаты

№	Center	диск, мм	А, мм	М, мм	Р, мм	Клин.%	Двояк.%
L1	(155, 49)	9,08	24	24	24	0	0
L2	(158, 91)	9,75	23	25	24	4,17	-4,17
L3	(158, 135)	10,69	25	25	25	0	0
L4	(156, 179)	13,84	28	26	28	0	7,14
L5	(152, 220)	0	27	17	0	100	37,04

Рисунок 42 – Результаты сохраняются в таблице Excel.

Заключение

В ходе данной работы был разработан нейросетевой алгоритм автоматической сегментации позвонков и определения типа и степени их деформации. В качестве алгоритма сегментации позвонков была использована глубокая сверточная нейронная сеть Mask RCNN, которая получила широкое применения для экземплярной сегментации объектов. Обучение и тестирование такой сети было выполнено на набор данных, из 200 пациентов (из них 100 без признаков патологии и 100 явным наличием деформации).

Для автоматической оценки наличия деформация и определения ее типа и степени был разработан еще один алгоритм, который анализировал форму масок позвонков, отсегментированных нейронной сетью. Эта процедура автоматически определяла параметры позвонков и оценивала тип и степень их деформации.

Качество сегментации с помощью коэффициент Дайса, который составил на тестовой выборке 0.95.

Благодарность

Выражаю благодарность своему научному руководителю Ильясову Камиллю Ахатовичу за помощь выполнения дипломной работы.

Хочу выразить благодарность коллегам по данному проекту к.ф-м.н. Бруй Екатерина Алексеевна и к.т.н Аль-Хайдри Валид, (Физический факультета ИТМО, Санкт-Петербург) за помощь в работе и ценные консультации.

Также хочу поблагодарить сотрудников ООО "БАРСМЕД", г.Казань за предоставленные МРТ-снимки.

Использованная литературы

1. Sprawls, P. Magnetic resonance imaging: principles, methods, and techniques / P. Sprawls. – Madison: Medical Physics Publishing, 2000. – P. 173. Текст: непосредственный.
2. Malhotra, P. Deep neural networks for medical image segmentation. – Текст: непосредственный / P. Malhotra. // Journal of Healthcare Engineering. – 2022. – P. 1-12.
3. Thoma, M. A survey of semantic segmentation. – Текст: непосредственный / Thoma M. // arXiv preprint arXiv. – 2016. – P. 1-10.
4. He, Kaiming. Mask r-cnn. – Текст: непосредственный / К. Не // Proceedings of the IEEE international conference on computer vision. – 2017. – P. 2961-2969.
5. Malhotra, P. Computer aided diagnosis of pneumonia from chest radiographs. – Текст: непосредственный / P. Malhotra. // Journal of Computational and Theoretical Nanoscience 16.10. – 2019. – P. 4202-4213.
6. Jain, V. Natural image denoising with convolutional networks. – Текст: непосредственный / Jain, V. // Advances in neural information processing systems 21. – 2008. – P. 1-7.
7. Lee, Honglak. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations. – Текст: непосредственный / Н. Ли. // Proceedings of the 26th annual international conference on machine learning. – 2009. – P. 609-616.
8. Zeiler, M. Deconvolutional networks. – Текст: непосредственный / М. Зеилер. // 2010 IEEE Computer Society Conference on computer vision and pattern recognition. IEEE. – 2010. – P. 2528-2535.

9. Shelhamer, E. Fully convolutional networks for semantic segmentation. – Текст: непосредственный / E. Shelhamer. // IEEE transactions on pattern analysis and machine intelligence 39.4. – 2017. – P. 640-651.
10. Ronneberger, O. U-net: Convolutional networks for biomedical image segmentation. – Текст: непосредственный / O. Ronneberger. // Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18. Springer International Publishing. – 2015. – P. 234-241.
11. Girshick, R. Fast r-cnn. – Текст: непосредственный / Girshick, R. // Proceedings of the IEEE international conference on computer vision. – 2015. – P. 1440-1448.
12. Priyanka, M. Comprehending Object Detection by Deep Learning Methods and Algorithms. – Текст: непосредственный / M. Priyanka // Mobile Computing and Sustainable Informatics: Proceedings of ICMCSI 2022. Singapore: Springer Nature Singapore. – 2022. – P. 523-537.
13. Chen, L. Encoder-decoder with atrous separable convolution for semantic image segmentation. – Текст: непосредственный / L. Chen. // Proceedings of the European conference on computer vision (ECCV). – 2018. – P. 801-818.
14. Mulay, S. Liver segmentation from multimodal images using HED-mask R-CNN. – Текст: непосредственный / S. Mulay. // Multiscale Multimodal Medical Imaging: First International Workshop, MMMI 2019, Held in Conjunction with MICCAI 2019, Shenzhen, China, October 13, 2019, Proceedings 1. Springer International Publishing. – 2020. – P. 68-75.
15. Chen, L. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. – Текст: непосредственный / L. Chen. // IEEE transactions on pattern analysis and machine intelligence 40.4. – 2017. – P. 834-848.

- 16.Шубкин, Е. Обзор методов сегментации медицинских изображений. – Текст: непосредственный / Е. Шубкин. // Молодежь и современные информационные технологии: сборник трудов XVIII Международной научно-практической конференции студентов, аспирантов и молодых учёных, 22-26 марта 2021 г., г. Томск. Томский политехнический университет. – 2021. – Р. 90-91.
- 17.Dice, L. Measures of the amount of ecologic association between species. – Текст: непосредственный / L. Dice. // Ecology 26.3. – 1945. – Р. 297-302.