

Сегментация легочных узлов на снимках компьютерной томографии

А. Р. Теплякова

Обнинский институт атомной энергетики – филиал Национального исследовательского ядерного университета «МИФИ», Обнинск, Россия

Аннотация. В статье описывается решение задачи автоматизации процесса сегментации легочных узлов на снимках компьютерной томографии для расширения функционала разработанного ранее модуля определения размеров и объемов легочных узлов. Акцент в работе делается на сравнении точности работы моделей, имеющих архитектуры ResU-Net, Attention U-Net и Dense U-Net, при обучении на снимках компьютерной томографии в исходном виде и с применением двух предлагаемых трехканальных подходов к их предварительной обработке. Для трех рассмотренных архитектур достигнуты значения коэффициента схожести Дайса и пересечения над объединением в диапазонах 0,8570–0,8735 и 0,7545–0,7881 при обучении на трехканальных снимках с усреднением. Полученные результаты позволяют сделать вывод о том, что применение методов предварительной обработки является перспективным для повышения точности сегментации. Также в статье описано обучение модели сегментации долей легких. Доработанный программный модуль принимает на вход снимки компьютерной томографии, а его выходные данные представляют собой обработанные снимки и структурированный отчет DICOM SR.

Ключевые слова: компьютерное зрение, сегментация, рак легкого, легочный узел, компьютерная томография, медицинские снимки, диагностика, система поддержки принятия врачебных решений.

DOI 10.14357/20718632240407 EDN DZNFQR

Введение

На протяжении последних лет рак легкого является первым по заболеваемости и смертности среди всех видов рака в мире [1]. Авторы статьи [2] исследовали статистические данные о заболеваемости раком легкого (за 1993–2021 годы) и смертности (за 1965–2021 годы) в России и пришли к выводу о том, что распространение использования компьютерной томографии (КТ) за последние 20 лет более, чем в 7 раз, оказало влияние на снижение смертности от рака легкого за счет повышения выявляемости этого заболевания. Проведение скрининга рака легкого (СРЛ) позволяет выявлять образования в легких

на ранних стадиях заболевания и снижать процент смертельных исходов, поэтому разработка и развитие программных инструментов, которые бы снижали рутинную нагрузку на специалистов-рентгенологов при проведении СРЛ, является важной задачей. Автоматизация этапов СРЛ за счет применения моделей и методов компьютерного зрения может ускорить и упростить процесс его проведения. Целью данной статьи является описание расширения функциональных возможностей модуля, разработанного на предыдущем этапе исследования и описанного в работе [3], за счет автоматизации этапа сегментации легочных узлов.

1. Постановка задачи исследования

В основе СРЛ лежит анализ снимков, получаемых в результате выполнения низкодозной КТ. Специалисту-рентгенологу необходимо просмотреть все снимки томографического исследования, оконтурить обнаруженные на них узлы, после чего определить их размеры и объемы в соответствии с рекомендациями по ведению легочных узлов Британского торакального общества, Флайшнеровского общества, Европейского консорциума по скринингу рака легкого или Lung-RADS [4] для принятия решения о планировании лечения пациента. Для снижения нагрузки на рентгенолога формирование масок бинарной сегментации легочных узлов, соответствующих аксиальным срезам КТ, может выполняться моделями компьютерного зрения. Перед выполнением этапа расчета количественных показателей легочных узлов полученные маски могут анализироваться и корректироваться рентгенологом.

Задача исследования сводится к автоматизации процесса получения масок сегментации легочных узлов и доработке разработанного ранее модуля определения их размеров и объемов. Могут быть выделены следующие подзадачи:

- формирование набора для обучения модели сегментации долей легких (снимки КТ в базовом виде и соответствующие им маски мультиклассовой сегментации);
- обучение модели сегментации долей легких;
- разработка программного кода для реализации двух трехканальных алгоритмов предварительной обработки снимков КТ легких;
- формирование наборов для обучения и тестирования моделей сегментации легочных узлов (снимки КТ в базовом виде, обработанные двумя предлагаемыми методами и соответствующие маски бинарной сегментации);
- обучение моделей сегментации легочных узлов, оценка влияния предобработок, выбор оптимального подхода;
- доработка алгоритма предоставления специалисту-рентгенологу необходимой информации (оконтуривание долей легких, дополнение DICOM SR информацией о долях, в которых обнаруживаются узлы);
- внедрение новых моделей и алгоритмов в ранее разработанный модуль.

2. Обзор существующих решений и описание предлагаемого подхода

Рассмотрен ряд публикаций, в которых описываются подходы к решению задачи сегментации легочных узлов по снимкам КТ и приводятся результаты их тестирования на данных из набора LIDC-IDRI [5]. В большинстве работ приводятся достигнутые подходами значения коэффициента схожести Дайса (Dice Similarity Coefficient, DSC) и пересечения над объединением (Intersection over Union, IoU).

Авторы [6] предлагают рассматривать серию снимков КТ-исследования как набор кадров видео и использовать для решения задачи сегментации легочных узлов методы оптического потока, принимая узлы за движущиеся объекты. Для 16 рассмотренных в работе узлов значения точности, чувствительности и специфичности составили 0,9, 0,745 и 0,9. В работе [7] предлагается архитектура UGMCS-Net, включающая механизм внимания с учетом неопределенности и позволяющая учитывать информацию о консенсусе и разногласиях нескольких аннотаций. Получены значения DSC 0,8765 и IoU 0,7878. Авторы [8] предлагают использовать для сегментации узлов комбинацию ResNeXt, UNet++ и модуля внимания SCSCE. Сегментации подвергается предварительно выделяемая область интереса, содержащая легкие, достигаются DSC 0,8343 и IoU 0,7251. В работе [9] значения DSC 0,8205 и IoU 0,7539 достигаются при использовании базовой версии U-Net. Предлагаемая в [10] пирамidalная архитектура на основе внимания Lung_PAYNet, кодер и декодер в которой спроектированы с использованием инвертированного остаточного блока, достигает значений DSC 0,957 и IoU 0,9175. Особенность SAtUNet, представленной в работе [11], заключается в использовании серии объединенных расширенных сверточных блоков после каждого этапа на путях кодера и декодера. Эта архитектура демонстрирует DSC 0,8110 и IoU 0,7224. Авторы [12] предлагают MDRU-Net – модификацию U-Net, которая, подобно SAtUNet, включает расширенные свертки для расширения рецептивного поля, а также использует плотные блоки и остаточный механизм. MDRU-Net достигает значений DSC 0,9237 и IoU 0,9213. Авторы [13]

предлагают применение функции унифицированных фокальных потерь при обучении 3D nnUNet, улучшенной за счет использования блока Res2Net и расширенной свертки. Предлагаемая архитектура демонстрирует DSC 0,834. В [14] представлена архитектура для сегментации легочных узлов 3DSqU² Net, применяющая полномасштабные пропускные соединения и глубокий надзор, идея которого заключается в добавлении сопутствующих целевых функций на каждом скрытом слое. 3DSqU² Net продемонстрировала значение IoU 0,9135. В [15] представлена архитектура трехмерной сегментации Dig-CS-VNet – улучшенная версия V-Net, основанная на пороговом разделении пикселей и применении механизма внимания. Продемонстрированы значения DSC 0,949 и IoU 0,903. Архитектура для сегментации узлов, предложенная авторами [16], использует обрезанные области исходных снимков КТ, имеющие различные размеры, и достигает значений DSC 0,982 и IoU 0,964. В работе [17] приводятся результаты сравнения метрик, полученных для архитектур U-Net, SegNet, GCN, FCN, DeepLabV3+, PspNetNet TransUNet, SwinUNet при сегментации узлов на обычных и на предварительно обработанных снимках КТ. Рассмотрены два способа обработки: наложение маски на пиксели, лежащие за пределами легких, и обрезка областей интереса. Авторы делают вывод, что второй подход повышает точность сегментации. Для 8 рассмотренных в работе архитектур DSC принимает значения от 0,816 до 0,887.

Суть подавляющего большинства существующих подходов к сегментации легочных узлов заключается в повышении точности за счет создания новых архитектур или модификации уже существующих, однако методам предварительной обработки уделяется мало внимания несмотря на то, что они также могут обеспечивать повышение точности.

2.1. Теоретическое описание предлагаемого подхода

В настоящей работе основной акцент делается на изучении влияния предлагаемых методов предобработки снимков КТ на метрики моделей сегментации легочных узлов, имеющих архитектуры ResU-Net, Attention U-Net и Dense

U-Net. Все три рассматриваемые в работе архитектуры представляют собой модификации U-Net и включают в себя пути сжатия (кодер) и расширения (декодер). Что касается отличительных особенностей, то:

- ResU-Net использует остаточные соединения, которые обеспечивают возможность изучения остаточных признаков с учетом входных данных;
- Attention U-Net использует ворота внимания, благодаря которым учится фокусироваться на существенных деталях, имеющих различные размеры и формы;
- Dense U-Net использует плотные блоки, благодаря чему достигаются увеличение глубины и повторное использование признаков.

Также в рамках исследования производится расширение функционала ранее разработанного модуля за счет реализации автоматической сегментации долей легких и легочных узлов. В рамках расширения функционала обучена модель сегментации долей легких, которая заменила модель бинарной сегментации паренхимы легкого, применявшуюся в предыдущей версии модуля. Обученная модель имеет архитектуру Attention U-Net и позволяет получать маски мультиклассовой сегментации, показывающие, к какому из шести классов (один соответствует фону, пять – долям легких) относится каждый пиксель. Схема, приведенная на Рис. 1, демонстрирует логику функционирования модуля с учетом описываемых изменений.

Для автоматического получения масок бинарной сегментации легочных узлов, соответствующих срезам загружаемых исследований, обучено 9 моделей сегментации легочных узлов, имеющих архитектуры ResU-Net, Attention U-Net, Dense U-Net и работающих с различными типами входных данных: одноканальными снимками и трехканальными, полученными при помощи двух предлагаемых подходов к предобработке. Первый из этих подходов ранее уже применялся при решении задачи сегментации мышечной ткани на отдельных снимках КТ и позволил повысить точность сегментации для ряда случаев [18]. Второй учитывает специфику решаемой в рамках данного исследования задачи, связанную с необходимостью анализа набора снимков. Первый и третий каналы в




Рис. 1. Схема, демонстрирующая логику работы модуля

обоих подходах представляются изображениями в базовом виде и с применением анизотропной диффузной фильтрации. Второй канал в первом подходе представляется изображением с применением адаптивного выравнивания гистограмм с ограниченным усилением контраста, во втором – усредненным изображением.

Изображение в базовом виде представляет собой массив пикселей, извлеченный из тега PixelData (7FE0,0010) файла DICOM и обработанный определенным образом. Суть обработки заключается в переходе от значений, выдаваемых томографом, к единицам Хаунсфилда (Hounsfield Units, HU). Уровень и ширина окна принимаются за -600 и 1600. Чтобы ограничить область интереса (преобразовать пиксели за пределами тела пациента в черные), также анализируется изображение, полученное для уровня и ширины окна, равных -50 и 450. К нему применяется порог, что позволяет получить бинарную маску, соответствующую области интереса.

Пример фрагмента изображения в базовом виде показан на Рис. 2, а. Усредненное изображение (Рис. 2, б) позволяет обогатить входные данные информацией, получаемой из срезов, соседних к рассматриваемому. Оно формируется следующим образом: вычисляется среднее изображение для текущего аксиального среза, предшествующего ему и следующего за ним. Для формирования изображения с применением адаптивного выравнивания гистограмм с ограниченным усилением контраста (Contrast Limited Adaptive Histogram Equalization, CLAHE) предел отсечения принят равным 2 (пример фрагмента на Рис. 2, в). Применение анизотропной диффузной фильтрации (Anisotropic Diffusion Filtering, ADF) позволяет сгладить изображение, при этом не размывая края и сохранив детали мелких структур [19], что является важным условием при работе со снимками КТ. ADF – преобразование, в основе которого лежит итеративное создание семейства




Рис. 2. Фрагменты изображений, формирующих трёхканальные снимки: базового (а), усреднённого (б), с применением CLAHE (в) и ADF (г)

изображений, для получения каждого последующего из которых применяется набор вычислений (в качестве начального изображения выступает исходное). Уравнение ADF записывается следующим образом [20]:

$I_t = \operatorname{div}(c(x, y, t) \nabla I) = c(x, y, t) \Delta I + \nabla c \cdot \nabla I$, где div обозначает дивергенцию, ∇ – градиент, Δ – лапласиан, $c(x, y, t)$ – коэффициент диффузии. Создатели ADF, П. Перона и Д. Малик, предложили две функции для расчета коэффициента диффузии, одна из которых использовалась в настоящей работе:

$$c(x, y, t) = g(\|\nabla I(x, y, t)\|) = e^{-\left(\frac{\|\nabla I\|}{K}\right)^2}.$$

Значение K оказывает влияние на чувствительность к краям и выбирается экспериментально. Для подготовки изображений с применением ADF в рамках настоящего исследования K принято равным 50, количество итераций ADF – 2. Пример фрагмента изображения в базовом виде, к которому применена ADF, показан на Рис. 2, г.

3. Практическая реализация

Для создания, обучения и тестирования моделей сегментации применен Keras, представляющий собой верхнеуровневый программный интерфейс приложения (Application Programming Interface, API) для платформы TensorFlow. Для обработки изображений использована библиотека OpenCV, для работы с файлами DICOM – пакет Pydicom.

Для оценки моделей сегментации долей легких и легочных узлов использовались две метрики: DSC и IoU. Для их расчета применяются следующие формулы:

$$\begin{aligned} DSC &= 2 \cdot \frac{|pred \cap ground_truth|}{|pred| + |ground_truth|}, \\ IoU &= \frac{|pred \cap ground_truth|}{|pred \cup ground_truth|} \end{aligned}$$

где $pred$ – предсказанная моделью маска, а $ground_truth$ – истинная. Стоит отметить, что в случае мультиклассовой сегментации долей легких перед расчетом метрик выполняется преобразование масок из одноканальных массивов, пикселям которых соответствуют значения от 0 до 5, в такие бинарные маски, каждый канал

которых соответствует отдельному классу (One Hot Encoding). Все модели обучались и тестировались на снимках размером 512×512 пикселей.

3.1. Сегментация долей легких

Набор данных для обучения модели сегментации долей легких сформирован из данных набора TotalSegmentator (версия 2.0.1). Этот набор содержит 1228 случайно отобранных в рамках клинической практики исследований КТ со 117 сегментированными анатомическими структурами [21]. Метки классов, соответствующие пикселям масок сегментации, следующие:

- 0 для фона;
- 1 для нижней доли левого легкого;
- 2 для верхней доли левого легкого;
- 3 для нижней доли правого легкого;
- 4 для средней доли правого легкого;
- 5 для верхней доли правого легкого.

Пример снимка КТ и соответствующей ему маски сегментации долей легкого показан на Рис. 3 (выбранный аксиальный срез содержит все доли, кроме верхней доли правого легкого).

Для обучения модели сегментации долей легких из TotalSegmentator было отобрано 109930 пар «снимок КТ, соответствующая ему маска мультиклассовой сегментации» (для обучения и валидации – 98126 пар, для тестирования – 11804). Значения метрик DSC и IoU обученной модели, рассчитанные на тестовой выборке, составляют 0,9791 и 0,9591. Модель внедрена в модуль не только для определения того, к каким долям относятся обнаруживаемые узлы, но и для ограничения области интереса, соответствующей легким, с целью уменьшения количества аксиальных срезов, которые обрабатываются моделью сегментации легочных узлов (это позволяет экономить вычислительные и временные ресурсы, затрачиваемые на обработку одного исследования).

3.2. Сегментация легочных узлов

Наборы для обучения моделей сегментации легочных узлов были сформированы из данных набора LIDC-IDRI, содержащего в общей сложности 1018 исследований КТ грудной клетки, собранных ретроспективно для 1010 уникальных пациентов. В LIDC-IDRI вошли исследования как со стандартной, так и с низкой дозами.



Рис. 3. Пример снимка КТ (а) и соответствующей ему маски сегментации долей лёгких (б)

В процессе аннотации набора, включавшем фазы слепой и повторной открытой обработки исследований, принимали участие 12 рентгенологов. Каждое исследование отсматривалось четырьмя рентгенологами, каждый обнаруженный узел идентифицировался как:

1. узел, размер которого больше или равен 3 мм;
2. узел, размер которого менее 3 мм;

3. не узел (к этой категории относились другие легочные поражения, размеры которых более и равны 3 мм).

Для всех узлов, отнесенных к первой категории (размер ≥ 3 мм), выполнялось оконтуривание [22]. В подвыборку, содержащую только исследования с оконтуренными узлами, попало 875 серий снимков КТ [23]. Снимки 708 из них вошли в обучающую выборку, 79 – в валидационную, 85 – в тестовую (в общей сложности для обучения и валидации моделей использовалась 13071 пара «снимок КТ, соответствующая ему маска бинарной сегментации легочных узлов», для тестирования – 1503 пары).

На базе полученного набора пар снимков и масок были подготовлены три набора данных: одноканальный и два трехканальных. Для их создания был написан программный код, реализующий предобработки, суть которых изложена в теоретическом описании предлагаемого подхода.

Для каждой из трех рассматриваемых архитектур (ResU-Net, Attention U-Net, Dense U-Net) было обучено по три модели на входных данных трех типов:

- одноканальные изображения;
- трехканальные изображения, второй канал в которых представляется снимками с применением CLAHE;
- трехканальные изображения, второй канал в которых представляется усредненными снимками.

Стоит отметить, что 9 обученных моделей тестировались на данных того же типа, что и данные, на которых производилось их обучение. Значения метрик DSC и IoU, рассчитанные для моделей, приведены в Табл. 1. Для всех трех архитектур лучшие значения DSC (0,8570–0,8735) и IoU (0,7568–0,7881) продемонстрировали модели, обученные на снимках, к которым применен предложенный подход к предобработке с усреднением. Что касается моделей, обученных на данных, полученных с применением метода предобработки с CLAHE, для ResU-Net такая версия дала самые низкие значения DSC и IoU, а для Attention U-Net и Dense- U-Net – превосходящие метрики моделей с одноканальными входными данными, но уступающие метрикам моделей, работающих на трехканальных данных

Табл. 1. Значения DSC и IoU

Тип входных снимков	Архитектуры моделей сегментации		
	ResU-Net	Attention U-Net	Dense U-Net
Значения DSC			
одноканальные	0,8495	0,8509	0,8488
трехканальные с CLAHE	0,8420	0,8529	0,8526
трехканальные с усреднением	0,8570	0,8719	0,8735
Значения IoU			
одноканальные	0,7091	0,6973	0,6878
трехканальные с CLAHE	0,6967	0,7014	0,7030
трехканальные с усреднением	0,7568	0,7881	0,7545

с усреднением. Из моделей, обученных на трехканальных данных с усреднением, для внедрения в программный модуль выбрана модель с архитектурой Attention U-Net, так как она имеет значение DSC, близкое к достигнутому моделью с архитектурой Dense U-Net, при этом превосходит ее по IoU, а также затрачивает на предсказание в 1,55 меньше времени (временная оценка усреднена для предсказаний на вычислительных устройствах с графическим процессором и без него), что является немаловажным фактором при необходимости обработки большого количества снимков.

3.3. Представление выходных данных

В качестве входных данных доработанного модуля выступают снимки КТ, хранящиеся в файлах DICOM. Эти снимки преобразуются с применением методов предварительной обработки и подаются на вход моделей сегментации для формирования бинарных масок легочных узлов и мультиклассовых масок долей легких. Массив масок, выдаваемый моделью сегментации легочных узлов, поступает на вход алгоритмов количественной оценки узлов в соответствии с рекомендациями по ведению легочных узлов Британского торакального общества, Флейшнеровского общества, Европейского консорциума по скринингу рака легкого и Lung-RADS. Реализация этих алгоритмов подробно описана в работе [3]. Алгоритм формирования выходных данных модифицирован с учетом того, что для каждого узла стала доступна информация о том, в какой доле легкого он находится. В формируемом модулем структурированном отчете содержатся метаданные исследования, информация об объеме, двумерных размерах каждого из узлов, а также указание долей. Помимо отчета,




Рис. 4. Пример аксиального среза с нанесёнными размерами узлов и контурами долей лёгких

модулем формируются изображения, представляющие собой обработанные аксиальные срезы КТ, содержащие узлы. На эти изображения наносятся дата и время обработки исследования модулем, контуры узлов, размеры их коротких и длинных осей (в мм), а также порядковые номера для удобства соотнесения с данными об узлах, содержащимися в DICOM SR. Также оконтурируются доли легких. Пример формируемого изображения показан на Рис. 4.

Заключение

Выполнена доработка разработанного ранее программного модуля определения размеров и объемов легочных узлов, благодаря которой

может быть снижена нагрузка на рентгенологов на этапе формирования масок бинарной сегментации легочных узлов. Модуль в текущей версии выполняет анализ снимков КТ, в автоматическом режиме сегментирует легочные узлы, после чего определяет их размеры и объемы в соответствии с используемыми при проведении СРЛ рекомендациями по ведению легочных узлов. Также добавлен функционал сегментации долей легких и определения принадлежности к ним обнаруживаемых узлов.

Для решения задачи автоматизации процесса сегментации легочных узлов обучено 9 моделей с архитектурами ResU-Net, Attention U-Net и Dense U-Net. Из данных LIDC-IDRI сформировано три набора данных, содержащих снимки КТ в исходном виде и с применением двух предлагаемых трехканальных методов предобработки. Для всех трех рассмотренных архитектур лучшие значения DSC и IoU продемонстрировали модели, обученные на трехканальных снимках с усреднением (первый канал представляется изображением в базовом виде, второй – изображением с применением анизотропной диффузной фильтрации, третий – изображением, являющимся средним трех соседних аксиальных срезов). Лучшее значение DSC (0,8735) из обученных в рамках исследования моделей продемонстрировала модель с архитектурой Dense U-Net, а IoU (0,7881) – с архитектурой Attention U-Net. В модуль внедрена модель с архитектурой Attention U-Net, работающая с трехканальными снимками с усреднением. Значения метрик DSC и IoU обученной на данных набора TotalSegmentator модели мультиклассовой сегментации долей легких, имеющей архитектуру Attention U-Net, составляют 0,9791 и 0,9591.

В рамках дальнейшей доработки разработанного программного модуля возможна реализация функционала автоматической классификации легочных узлов. Также интерес представляет исследование влияния предложенного трехканального метода предобработки снимков КТ с усреднением на точность моделей сегментации различных тканей и органов.

Литература

- Siegel R. L., Giaquinto A. N., Jemal A. Cancer statistics // CA: A Cancer Journal for Clinicians. 2024. Vol. 74(1). P. 12–49.
- Tursun-zade R. et al. Sex differences in lung cancer incidence and mortality in Russia in the light of computed tomography usage expansion: breakpoint and age-period-cohort analyses // Cancer Epidemiology. 2024. Vol. 93. P. 102654.
- Тепликова А. Р. Разработка модуля определения размеров и объемов легочных узлов // Информационные технологии и вычислительные системы. 2024. №1. С. 46–55.
- Гомболевский В. А. и др. Основные достижения низкодозной компьютерной томографии в скрининге рака легкого // Туберкулез и болезни легких. 2021. № 99 (1). С. 61–70.
- Armato 3rd S. G. et al. Data From LIDC-IDRI [Data set] // The Cancer Imaging Archive. 2015.
- Suji R. J. Et al. Optical Flow Methods for Lung Nodule Segmentation on LIDC-IDRI Images // Journal of Digital Imaging. 2020. Vol. 33(5). P. 1306–1324.
- Yang H. et al. Lung Nodule Segmentation and Uncertain Region Prediction With an Uncertainty-Aware Attention Mechanism // IEEE Transactions on Medical Imaging. 2024. Vol. 43(4). P. 1284–1295.
- Dong L., Liu H. Segmentation of Pulmonary Nodules Based on Improved UNet++ // Proceedings of the 14th International Congress on Image and Signal Processing, Bio-Medical Engineering and Informatics (CISP-BMEI). Shanghai, China, 2021. P. 1-5.
- Niranjan Kumar S. et al. Lung Nodule Segmentation Using UNet // Proceedings of the 7th International Conference on Advanced Computing and Communication Systems (ICACCS). 2021. P. 420-424.
- Bruntha P.M. et al. Lung_PAYNet: a pyramidal attention based deep learning network for lung nodule segmentation // Scientific Reports. 2022. Vol. 12. P. 20330.
- Selvadass S. et al. SAtUNet: Series atrous convolution enhanced U-Net for lung nodule segmentation // International Journal of Imaging Systems and Technology. 2024. Vol. 34(1). P. 22964.
- Zhang, X. et al. Lung Nodule CT Image Segmentation Model Based on Multiscale Dense Residual Neural Network // Mathematics. 2023. Vol. 11(6). P. 1363.
- Chen Y. A. et al. Lung Nodule Segmentation in LDCT: Modified 3D nnUNet with Unified Focal Loss // Proceedings of the International Conference on Electrical, Computer and Energy Technologies (ICECET 2023). Cape Town, South Africa, 2023.
- Ghasemi S. et al. RePoint-Net detection and 3DSqU² Net segmentation for automatic identification of pulmonary nodules in computed tomography images // Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization. 2023. Vol. 12(1). P. 2258998.
- Ma X. et al. An improved V-Net lung nodule segmentation model based on pixel threshold separation and attention mechanism // Scientific Reports. 2024. Vol. 14. P. 4743.

16. Sweetline B. C. Overcoming the Challenge of Accurate Segmentation of Lung Nodules: A Multi-crop CNN Approach // Journal Of Imaging Informatics In Medicine. 2024 Vol. 37(3). P.988–1007.
17. Chen W. et al. CT Lung Nodule Segmentation: A Comparative Study of Data Preprocessing and Deep Learning Models // IEEE Access. 2023. Vol. 11. P. 34925–34931.
18. Теплякова А.Р., Шершнев Р.В., Старков С.О. Метод сегментации мышечной ткани на снимках компьютерной томографии на базе предобработанных трехканальных изображений // Научно-технический вестник информационных технологий, механики и оптики. 2024. № 4, Т. 24. С. 661–664.
19. Kaur R., Juneja M., Mandal A.K. A comprehensive review of denoising techniques for abdominal CT images // Multimedia Tools and Applications. 2018. Vol. 77(17). P. 22735–22770.
20. Perona P., Malik J. Scale-Space and Edge Detection Using Anisotropic Diffusion // IEEE Transactions on Pattern Analysis and Machine Intelligence. 1990. Vol. 12(7). P. 629–639.
21. Wasserthal J. Dataset with segmentations of 117 important anatomical structures in 1228 CT images (2.0.1) [Data set] // Zenodo. 2023.
22. Armato 3rd S. G. et al. The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): a completed reference database of lung nodules on CT scans // Medical Physics. 2011. Vol. 38(2). P. 915–931.
23. Fedorov A. et al. Standardized representation of the TCIA LIDC-IDRI annotations using DICOM // The Cancer Imaging Archive. 2018.

Теплякова Анастасия Романовна. Обнинский институт атомной энергетики – филиал федерального государственного автономного образовательного учреждения высшего образования «Национальный исследовательский ядерный университет «МИФИ», Обнинск, Россия. Старший преподаватель, аспирант. Область научных интересов: компьютерное зрение, информационные технологии. E-mail: anastasija-t23@mail.ru.

Segmentation of Pulmonary Nodules on Computed Tomography Scans

A. R. Teplyakova

Obninsk Institute for Nuclear Power Engineering, Obninsk, Russia

Abstract. The article describes a solution to the problem of automating the process of segmentation of pulmonary nodules on computed tomography scans to expand the functionality of the previously developed module for determining the size and volume of pulmonary nodules. The main focus of the article is on comparing the accuracy of the models with the ResU-Net, Attention U-Net and Dense U-Net architectures when training on computed tomography images from the LIDC-IDRI dataset in their original form and using two proposed three-channel approaches to their preprocessing. For the three architectures considered, the DSC and IoU values in the ranges 0.8570–0.8735 and 0.7545–0.7881 were achieved. The best metric values were demonstrated by models trained on three-channel images with averaging. In such images, the first channel is represented by a scan in its original form, the second by an averaged scan, and the third by a scan to which anisotropic diffuse filtration is applied. The obtained results allow us to conclude that the use of preprocessing methods is promising for improving the accuracy of segmentation. The article also describes the training of the lung lobes segmentation model using data from the TotalSegmentator dataset. The input data of the modified software module are computed tomography scans, and its output data are processed images and a structured report (DICOM SR). This report, in addition to data on the size and volume of pulmonary nodules, contains information on the lobes in which the detected nodules are located.

Keywords: computer vision, segmentation, lung cancer, lung nodule, computed tomography, medical images, diagnostics, medical decision support system

DOI 10.14357/20718632240407 EDN DZNFQR

References

1. Siegel R. L., Giaquinto A. N., Jemal A. Cancer statistics. CA: A Cancer Journal for Clinicians. 2024;74(1):12–49. doi: 10.3322/caac.21820.
2. Tursun-zade R. et al. Sex differences in lung cancer incidence and mortality in Russia in the light of computed tomography usage expansion: breakpoint and age-period-cohort analyses. Cancer Epidemiology. 2024;93:102654. doi: 10.1016/j.canep.2024.102654.

3. Teplyakova A. R. Development of a Module for Determining the Size and Volume of Pulmonary Nodules. Informatonnnye tekhnologii i vychislitel'nye sistemy. 2024;1:46-55. (in Russ.). doi: 10.14357/20718632240105.
4. Gombolevskiy V. A. et al. Main achievements of low-dose computed tomography in lung cancer screening. Tuberculosis and lung diseases. 2021. 99(1):61-70 (in Russ.). doi: 10.21292/2075-1230-2021-99-1-61-70.
5. Armato 3rd S. G. et al. Data From LIDC-IDRI [Data set]. The Cancer Imaging Archive. 2015. doi: 10.7937/K9/TCIA.2015.LO9QL9SX.
6. Suji R. J. Et al. Optical Flow Methods for Lung Nodule Segmentation on LIDC-IDRI Images. Journal of Digital Imaging. 2020;33(5):1306-1324. doi: 10.1007/s10278-020-00346-w.
7. Yang H. et al. Lung Nodule Segmentation and Uncertain Region Prediction With an Uncertainty-Aware Attention Mechanism. IEEE Transactions on Medical Imaging. 2024;43(4):1284-1295. doi: 10.1109/TMI.2023.3332944.
8. Dong L., Liu H. Segmentation of Pulmonary Nodules Based on Improved UNet++. In: Proceedings of the 14th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). 2021. P. 1-5. doi: 10.1109/CISP-BMEI53629.2021.9624438.
9. Nirajan Kumar S. et al. Lung Nodule Segmentation Using UNet. In: Proceedings of the 7th International Conference on Advanced Computing and Communication Systems (ICACCS). 2021. P. 420-424. doi: 10.1109/ICACCS51430.2021.9441977.
10. Bruntha P.M. et al. Lung_PAYNet: a pyramidal attention based deep learning network for lung nodule segmentation. Scientific Reports. 2022;12:20330. doi: 10.1038/s41598-022-24900-4.
11. Selvadass S. et al. SAtUNet: Series atrous convolution enhanced U-Net for lung nodule segmentation. International Journal of Imaging Systems and Technology. 2024;34(1):22964. doi: 10.1002/ima.22964.
12. Zhang, X. et al. Lung Nodule CT Image Segmentation Model Based on Multiscale Dense Residual Neural Network. Mathematics. 2023;11(6):1363. doi: 10.3390/math11061363.
13. Chen Y. A. et al. Lung Nodule Segmentation in LDCT: Modified 3D nnUNet with Unified Focal Loss. In: Proceedings of the International Conference on Electrical, Computer and Energy Technologies (ICECET 2023). 2023. doi: 10.1109/ICECET58911.2023.10389288.
14. Ghasemi S. et al. RePoint-Net detection and 3DSqU² Net segmentation for automatic identification of pulmonary nodules in computed tomography images. Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization. 2023;12(1):2258998. doi: 10.1080/21681163.2023.2258998.
15. Ma X. et al. An improved V-Net lung nodule segmentation model based on pixel threshold separation and attention mechanism. Scientific Reports. 2024;14:4743. doi: 10.1038/s41598-024-55178-3.
16. Sweetline B. C. Overcoming the Challenge of Accurate Segmentation of Lung Nodules: A Multi-crop CNN Approach. Journal Of Imaging Informatics In Medicine. 2024;37(3):988-1007. doi: 10.1007/s10278-024-01004-1.
17. Chen W. et al. CT Lung Nodule Segmentation: A Comparative Study of Data Preprocessing and Deep Learning Models. IEEE Access. 2023;11:34925-34931. doi: 10.1109/ACCESS.2023.3265170.
18. Teplyakova A. R., Shershnev R. V., Starkov S. O. Method of muscle tissue segmentation in computed tomography images based on preprocessed three-channel images. Scientific and Technical Journal of Information Technologies, Mechanics and Optics. 2024;24(4):661-664. (in Russ.). doi: 10.17586/2226-1494-2024-24-4-661-664.
19. Kaur R., Juneja M., Mandal A.K. A comprehensive review of denoising techniques for abdominal CT images. Multimedia Tools and Applications. 2018;77(17):22735-22770. doi: 10.1007/s11042-017-5500-5.
20. Perona P., Malik J. Scale-Space and Edge Detection Using Anisotropic Diffusion. IEEE Transactions on Pattern Analysis and Machine Intelligence. 1990;12(7):629-639. doi: 10.1109/34.56205.
21. Wasserthal J. Dataset with segmentations of 117 important anatomical structures in 1228 CT images (2.0.1) [Data set]. Zenodo. 2023. doi: 10.5281/zenodo.10047292.
22. Armato 3rd S. G. et al. The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): a completed reference database of lung nodules on CT scans. Medical Physics. 2011;38(2):915-31. doi: 10.1118/1.3528204.
23. Fedorov A. et al. Standardized representation of the TCIA LIDC-IDRI annotations using DICOM. The Cancer Imaging Archive. 2018. doi: 10.7937/TCIA.2018.h7umfurq.

Teplyakova Anastasia R. Senior Lecturer, Postgraduate Student, Obninsk Institute for Nuclear Power Engineering, 1 Studgorodok, Obninsk, Kaluga region, 249039, Russia. E-mail: anastasija-t23@mail.ru