

Применение модели внешнего вида текстуры для сегментации легочных узлов при компьютерной томографии грудной клетки

Фаридоддин Шариати¹, В. А. Павлов^{1,2✉}, С. В. Завьялов¹,
Махди Оруджи³, Т. М. Первунина²

¹ Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербург, Россия

² Национальный медицинский Исследовательский центр имени В. А. Алмазова, Санкт-Петербург, Россия

³ Калифорнийский университет, Дэйвис, США

✉ pavlov_va@spbstu.ru

Аннотация

Введение. Рак легких ежегодно становится причиной более миллиона смертей во всем мире. Компьютерная диагностика (Computer-Aided Detection – CAD) является очень важным инструментом для идентификации поражений легких. В целом технологическую линию системы CAD можно разделить на четыре основных этапа: предварительную обработку, локализацию, извлечение признаков и классификацию. Поскольку для локализации при обработке медицинских изображений требуется сегментация, этот этап стал важной и сложной проблемой и было проведено много исследований новых методов сегментации.

Цель работы. Применение модели внешнего вида текстуры для сегментации легочных узлов при компьютерной томографии грудной клетки.

Материалы и методы. Предложена модель текстурного представления, которая является новым методом на основе модели и позволяет точно и эффективно сегментировать все типы узловых образований, включая околоплевральные узлы, не отделяя легкое от окружающей области при компьютерной томографии (КТ) легких. В этом методе текстурная репрезентация изображения получается с помощью алгоритмов выделения текстурных признаков ткани и выбора признаков.

Результаты. Предложенный метод был апробирован на 85 узелках из набора данных, полученных на базе иранской больницы Шариати. В этом обезличенном наборе сведений были представлены аннотации врачей и данные КТ. Результаты показывают, что предложенный алгоритм достигает среднего коэффициента сходства dice 84.75 %.

Заключение. Представлен новый алгоритм для сегментации узелков в легком, который может сегментировать все типы узелков с высокой производительностью. Этот алгоритм основан на модели и вместе с алгоритмом активного контура способен повысить точность и устранить ложные срабатывания за счет определения начальной маски. Результаты сегментации легочных узелков на нормальном КТ-изображении следующие: precision 85.5 %, dice 85 %, accuracy 96 % и specificity 98 %.

Ключевые слова: модель внешнего вида текстуры (ТАМ), извлечение признаков текстуры, система автоматизированного обнаружения (CADs), компьютерная томография (СТ), представление текстуры изображения (TRI)

Для цитирования: Применение модели внешнего вида текстуры для сегментации легочных узлов при компьютерной томографии грудной клетки / Фаридоддин Шариати, В. А. Павлов, С. В. Завьялов, Махди Оруджи, Т. М. Первунина // Изв. вузов России. Радиоэлектроника. 2022. Т. 25, № 3. С. 96–117. doi: 10.32603/1993-8985-2022-25-3-96-117

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Источник финансирования. Исследование выполнено при финансовой поддержке РФФИ и ННФИ в рамках научного проекта № 20-57-56018.

Благодарности. Результаты работы были получены с использованием вычислительных ресурсов суперкомпьютерного центра Санкт-Петербургского политехнического университета Петра Великого (www.scc.spbstu.ru).

Статья поступила в редакцию 11.03.2022; принята к публикации после рецензирования 15.04.2022; опубликована онлайн 28.06.2022

Application of a Texture Appearance Model for Segmentation of Lung Nodules on Computed Tomography of the Chest

Faridoddin Shariaty¹, Vitalii A. Pavlov^{1,2✉}, Sergey V. Zavjalov¹,
Mahdi Orooji³, Tatiana M. Pervunina²

¹ Peter the Great St. Petersburg Polytechnic University, St Petersburg, Russia

² Almazov National Medical Research Centre, St Petersburg, Russia

³ University of California, Davis, USA

✉ pavlov_va@spbstu.ru

Abstract

Introduction. Lung cancer is one of the most critical diseases globally, with more than 1.6 million new cases registered every year. Early detection of lung cancer is essential; therefore, particular attention should be paid to the development of effective diagnostic and therapeutic procedures. Computer processing of CT scans in the course of lung cancer diagnostics involves the following stages: medical image acquisition, pre-processing of medical images, segmentation, and false-positive reduction. Since segmentation is an essential stage in the process of medical image analysis, the development of novel segmentation approaches is attracting much research interest. Model-based segmentation approaches have recently gained in popularity, largely due to their potential to restore lost information.

Aim. To apply a texture appearance model for the segmentation of pulmonary nodules on computed tomography of the chest.

Materials and methods. A novel model-based Texture Appearance Model (TAM) is proposed for precise and effective segmentation of all sorts of nodule regions. We taught the TAM for segmentation of a lung nodule in lung CT images using a combination of extracted texture characteristics from CT scans and Texture Representation of Image (TRI).

Results. The results of applying the described TAM method to normal and noisy CT images are presented and compared to those obtained using the Region Growing and Active Contour algorithms, as well as the combination of Active Contour and Watershed algorithms. The TAM was tested in 85 nodules from a dataset, yielding an average dice similarity coefficient (DSC) of 84.75 percent.

Conclusion. A novel method for segmenting nodules in the lung, which is capable of segmenting all forms of nodules with excellent accuracy, is proposed. This model-based technique, when used with the active loop algorithm, can enhance accuracy and decrease false positives by selecting the initial mask. The precision, dice, accuracy, and specificity of lung nodule segmentation on a normal CT scan are 85.5, 85, 96, and 98, which levels are superior to those produced by the Active Contour, Region Growing and the combination of Active Contour and Watershed algorithms.

Keywords: Texture Appearance Model (TAM), Texture Feature Extraction, Computer-Aided Detection system (CADs), Computed Tomography scan (CT), Texture Representation of Image (TRI)

For citation: Faridoddin Shariaty, Pavlov V. A., Zavjalov S. V., Mahdi Orooji, Pervunina T. M. Application of a Texture Appearance Model for Segmentation of Lung Nodules on Computed Tomography of the Chest. Journal of the Russian Universities. Radioelectronics. 2022, vol. 25, no. 3, pp. 96–117. doi: 10.32603/1993-8985-2022-25-3-96-117

Conflict of interest. The authors declare no conflicts of interest.

Acknowledgements. The study was carried out with the financial support of the Russian Foundation for Basic Research and National Science Foundation of the Islamic Republic of Iran as part of a scientific project № 20-57-56018. The results of the work were obtained using the computing resources of the supercomputer center of Peter the Great St. Petersburg Polytechnic University (www.scc.spbstu.ru).

Submitted 22.03.2022; accepted 15.04.2022; published online 28.06.2022

Введение. Ежегодно в мире более чем у 1.6 млн пациентов диагностируется рак легких, что приводит более чем к одному миллиону смертей. В среднем 5-летняя выживаемость больных немелкоклеточным раком легкого

(НМРЛ), который является наиболее распространенным типом рака легкого, составляет 15 % [1]. Рак легких на сегодняшний день является ведущей причиной смерти от рака в мире, на его долю приходится почти 25 % всех смертей

от рака. Если рак легких обнаружен на ранних стадиях заболевания, когда узелок маленький и еще не успел распространиться, у него больше шансов на успешное лечение [2]. Современные клинические работы создают так много данных на одного пациента, что проанализировать всю информацию без компьютерных систем невозможно. Кроме того, анализ изображений и медицинской информации человеком имеет врожденную погрешность и может приводить к неправильной постановке диагноза [3]. Компьютерная система обнаружения (Computer-Aided Detection – CAD) является очень важным инструментом для диагностики поражений легких в медицинской визуализации.

В целом технологическую линию системы CAD можно разделить на четыре основных этапа: предварительную обработку, сегментацию, извлечение признаков и классификацию. Сегментация изображений является сложной и важной проблемой в анализе медицинских изображений и компьютерном зрении. Отметим, что в последние годы было проведено много исследований новых методов сегментации. Однако в этой области остается несколько проблем, среди которых можно выделить эффективную, надежную и автоматическую сегментацию анатомии на радиологических изображениях [4]. Основная цель сегментации изображений заключается в сохранении целевой области при удалении нежелательных маммографических данных [5]. Сегментация легочных узелков на КТ-изображениях является сложной и основной задачей CAD. Фактически многие методы количественной оценки легочных заболеваний автоматически требуют сегментации легочной паренхимы и узелков на этапе первичной обработки [6]. Методы сегментации можно разделить на несколько классов [7]: полностью основанные на изображении [8–10], основанные на модели [11] и гибридные методы [12]. Полностью основанные на изображении методы выполняют сегментацию, основываясь исключительно на информации, имеющейся в изображении. Морфологические операции [13], пороговое выделение, рост области [14], активные контуры [15], наборы уровней [16], водораздел [17] и нечеткая связь [18] являются примерами полностью основанных на изображении методов. Эти методы эффективно работают на высококачественных изображениях. Однако

иногда на поздней стадии рака легкого узелки, вероятно, расположены вблизи верхушки легкого, стенок, диафрагмы, кровеносных сосудов и т. д., где отсутствует легочная ткань, и информация о границах теряется. Эти несоответствия могут изменить результаты алгоритма сегментации, что приводит к низкой эффективности [19].

Основной причиной широкого использования компьютерных томографов является хорошая контрастность и видимость органов, однако наличие шума Гаусса снижает видимость объектов с низкой контрастностью на КТ-изображениях. Различение тканей с разной плотностью может быть ограничено в результате существующего случайного шума на медицинских изображениях. Шум соль/перец и спекл-шум возникают на изображениях КТ из-за деструктивной и конструктивной когерентной агрегации [8].

В последние годы подходы глубокого обучения также широко используются для сегментации узелков легких при компьютерной томографии. В [20] представили многоракурсную CNN (multi-view Convolutional Neural Network – MV-CNN) для сегментации легочных узелков, коэффициент кубизма алгоритма составил 77.67 %. В [21] авторы предложили синергетическую комбинацию глубокого обучения и наборов уровней, управляемых формой, для автоматической и точной сегментации узелка легкого. В [22] предложена система, которая эффективно сегментирует легочные узелки на КТ-сканах. Авторы рассмотрели систему в четырех основных модулях: обнаружение узла-кандидата с помощью Faster regional-CNN (FR-CNN), объединение кандидатов, уменьшение количества ложных срабатываний (FP) с помощью CNN и сегментация легочного узла с помощью полностью сверточной нейронной сети (FCN). Среднее значение коэффициента dice для сегментированного легочного узелка по сравнению с истиной составило 79 %. В [23] представили метод автоматизированной сегментации узлов легких на КТ-сканах с использованием графа-среза и предварительного глубокого обучения (Deep Learned prior based Graph Cut – DLGC). DLGC – это метод, который сочетает в себе глубокое обучение предварительной локализации элементов с функцией стоимости, специфичной для данной области, используя данные изображений низкого

уровня. Для твёрдых узелков DLGC получил среднюю оценку 0.69, 0.14 и для частичных солидных образований – 0.65, 0.13.

В последние годы алгоритмы сегментации на основе моделей становятся все более привлекательными. Если из изображения удалена информация, отсутствующие данные могут быть компенсированы за счет использования предыдущих в алгоритме на основе модели. Это является одним из преимуществ данного метода. Алгоритмы на основе моделей используют предыдущие данные о форме и очертаниях совокупности объектов, такие как статистические активные модели формы (Active Shape Modes – ASM) [24] и статистические активные модели внешнего вида (Active Appearance Models – AAM) [25]. Оба подхода основаны на создании модели распределения точек, которая принимает интересующую форму и затем резко усиливает ее вблизи ориентиров в случае ASM или текстуры объекта в случае AAM [26]. ASM имеют ряд недостатков и ограничений: 1) удаляют информацию о внешнем виде объекта везде, кроме границы объекта; 2) на ASM не влияют модели текстуры и внешнего вида [4]. AAM является одной из наиболее выдающихся методик [27], которая широко используется для извлечения признаков во многих приложениях [28], включая изучение поведения человека, моделирование лиц и задачи медицинской визуализации, такие как сегментация МРТ сердца или сегментация диафрагмы в данных КТ, а также регистрация в функциональной визуализации сердца [27]. В [29] авторы разработали алгоритм AAM как основу для статистического моделирования изменения формы и текстуры объекта. AAM включает (высокоуровневые) знания о текстуре (внешнем виде) и форме объекта и создает статистическую модель формы и внешнего вида каждого объекта.

В данной статье предложена модель внешнего вида текстуры (texture appearance model – TAM), которая представляет собой основанный на модели алгоритм, использующий извлечение текстурных признаков и выбор признаков для сегментации узелков легких на компьютерных томограммах. Насколько нам известно, данная работа представляет собой первую попытку ис-

пользовать комбинацию извлеченных текстурных признаков из КТ-скана и сделать текстурное представление изображения (TRI) для использования в TAM для различения узелка легкого и легочной ткани на КТ-изображениях легких. В заключение представлены результаты применения данного алгоритма на нормальных и зашумленных КТ-изображениях. Затем результаты применения представленного алгоритма сравниваются с алгоритмами Region Growing [30], Active Contour [31] и комбинацией алгоритмов Active Contour и Watershed [8].

Модель внешнего вида текстуры (TAM).

Алгоритм TAM включает следующие этапы:

- 1) извлечение признаков;
- 2) выбор признаков;
- 3) обучение модели.

1. *Извлечение признаков* является важным этапом в обработке изображений и распознавании образов. Признаки часто включают информацию о цвете, форме, текстуре или фоне [32]. Предлагаемый алгоритм извлечения признаков состоит из двух следующих признаков: радиомические признаки и признаки на основе текстуры. Методы радиомики извлекают огромное количество признаков из радиографических медицинских изображений с помощью алгоритмов характеристики данных. Текстурный признак используется для разделения и классификации изображений на области интереса. В изображении текстура предоставляет информацию о цветах и интенсивности. Географическое распределение уровней интенсивности в окрестности используется для характеристики текстуры.

В данной статье для статистического анализа тканей используется матрица совпадений на уровне серого (Gray-Level Co-Occurrence Matrix – GLCM). На рис. 1 показаны этапы извлечения признаков из входного изображения. В этом методе статистическая обработка выполняется над парой пикселей с заданной интенсивностью в пространственном соотношении для определения текстуры изображения и составления матрицы GLCM. В табл. 1 представлены основные признаки текстуры и формы, извлекаемые при КТ. Далее описываются извлеченные признаки.

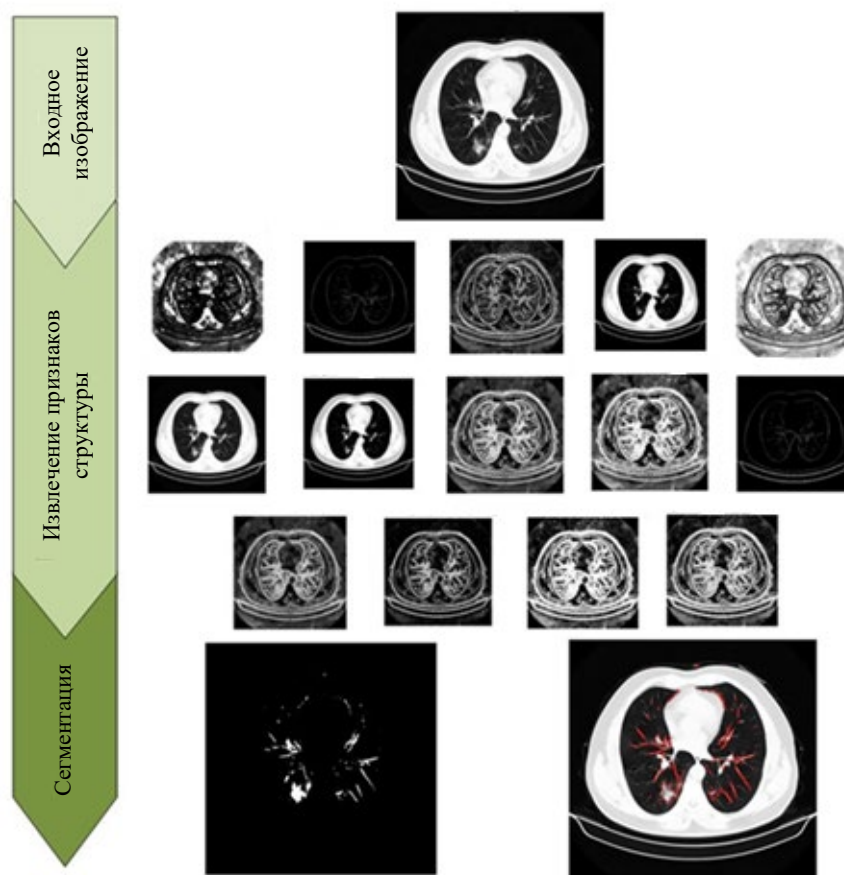


Рис. 1. Извлечение признаков и сегментация изображения на входном КТ-скане грудной клетки

Fig. 1. Feature extraction and image segmentation in an input CT scan of the chest

1.1. *Haralick*. В [33] для измерения пространственной связи между соседними пикселями в изображении предложили использовать матрицу совпадений уровня серого. Благодаря своей простоте и очевидной интерпретации текстурные признаки *Haralick*, которые вычисляются на основе GLCM, широко используются и были успешно применены в ряде приложений, включая анализ КТ легких [34]. В последние

годы признаки *Haralick* приобрели популярность при анализе медицинских изображений, например ультразвуковых и МРТ-изображений печени и сердца [35], рентгеновской маммографии [36] и МРТ-изображений при исследовании рака молочной железы [37], рака простаты [38] и рака мозга [39]. Он также используется в радиомике [40], новой технике извлечения большого числа

Табл. 1. Извлеченные компьютером особенности формы и текстуры, которые будут использоваться для характеристики конкреций на компьютерной томограмме

Tab. 1. Computer extracted shape and texture features to be used for nodule characterization on CT

Признак	Биологическая основа и связь с морфологией поражения
Статистика уровня серого (текстура)	Локализует области со значительными различиями интенсивности внутри узла
Управляемый Габор (текстура)	Ориентированные текстуры через изменения направления и масштаба захватывают микроархитектуры
Haralick (текстура)	Производные второго порядка, фиксирующие тонкие текстурные различия поражения
Law (текстура)	Пятна, рябь, волнообразные проявления
Фурье (форма)	Низкая частота: глобальная форма. Высокая частота: локальные детали
Явный дескриптор (форма)	Секулярность, угол наклона края, эффект ореола

количественных данных из медицинских изображений и использования их для создания моделей, предсказывающих такие вещи, как фенотип опухоли [41], выживаемость [42] и категоризацию [43].

1.2. *Gray*. В [33] ввели признак текстуры серого, который является структурным признаком второго порядка, основанным на матрицах GLCM в соответствии с целевыми областями полутонового изображения. Контраст, корреляция, обратный момент разности, угловой второй момент и энтропия – пять признаков текстуры серого, восстановленных в данном исследовании. Для получения этих характеристик используются следующие математические формулы:

$$f = \sum_{ij=0}^{N-1} \{P_{ij}(i-j)\}^2$$

– угловой второй момент;

$$f = \sum_{ij=0}^{N-1} P_{ij}(i-j)^2$$

– контраст;

$$f = \sum_{ij=0}^{N-1} P_{ij} \left[\frac{(i-\mu)(j-\mu)}{\sqrt{(\sigma_i)^2(\sigma_j)^2}} \right]$$

– корреляция;

$$f = \sum_{ij=0}^{N-1} P_{ij}(-\ln P_{ij})$$

– энтропия;

$$f = \sum_{ij=0}^{N-1} 1 - \frac{P_{ij}}{1 + (i-j)^2}$$

– обратный разностный момент, где f – выходные значения функций; P_{ij} – вероятность; i и j – индексы GLCM, извлеченные из изображения; μ – среднее значение; σ – стандартное отклонение.

1.3. *Абсолютный градиент* (Gradient – GRAD). Из каждой определенной градиентной матрицы КТ-скана был сформирован набор из пяти текстурных признаков. Среди них среднее значение, дисперсия, перекокс, эксцесс и момент. После создания гистограммы (His) матрицы градиентов генерируются градиентные признаки. Гистограмма рассчитывается для значений градиента, которые попадают в диапазон $[-255, 255]$.

Далее приведены характеристики градиента, которые были определены в [44]:

$$f = \sum_v \frac{\text{His}(v+255)v}{N}$$

– среднее значение;

$$f = \sum_v \frac{\text{His}(v+255)(v-\mu)^2}{N}$$

– отклонение;

$$f = \sum_v \frac{\text{His}(v+255)(v-\mu)^3}{N}$$

– перекокс;

$$f = \sum_v \frac{\text{His}(v+255)(v-\mu)^4}{N}$$

– коэффициент эксцесса;

$$f = \sum_v \frac{\text{His}(v+255)\sqrt{|v-\mu|}}{N}$$

– момент, где v – значение градиента, растянутое в диапазоне от -255 до 255 ; N – общее число пикселей.

1.4. *Фильтр Габора* [45] часто используется для извлечения текстурной информации из изображений. Согласно предыдущим работам [45], текстурные признаки Габора работают лучше, чем признаки древовидного вейвлет-преобразования (Tree-Structured Wavelet Transform – TWT), одновременной авторегрессионной модели многократного разрешения (Multiresolution Simultaneous Autoregressive Model – MR-SAR) и признаки пирамидного вейвлет-преобразования (Pyramid-Structured Wavelet Transform – PWT). В фильтрах Габора используются вейвлеты.

Свертка определяет вейвлет-преобразование Габора для входного изображения $I(x, y)$ размером $P \times Q$:

$$G_{mn}(x, y) = \sum_s \sum_t I(x-s, y-t) \psi_{mn}^*(s, t),$$

где m и n – масштаб и ориентация вейвлета соответственно; s и t – параметры фильтра; ψ_{mn}^* –

комплексный ψ_{mn} , который использует вращение и расширение материнского вейвлета для построения серии сравнимых функций:

$$\psi_{m,n}(x,y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right)\right] \times \exp(j2\pi Wx).$$

Здесь W – частота модуляции в этом уравнении, а Габор-подобные вейвлеты формируются с помощью следующей функции генерации:

$$\psi_{mn}(x,y) = a^{-m}\psi_{mn}(\tilde{x},\tilde{y}),$$

где a – фиксированный коэффициент; m и n обозначают масштаб и ориентацию вейвлета соответственно, так что $m = 0, 1, \dots, M-1$; $n = 0, 1, \dots, N-1$. В предположении, что $a > 1$ и $\theta = n\pi/N$, \tilde{x} и \tilde{y} определяются следующим образом:

$$\tilde{x} = a^{-m}(x \cos \theta + y \sin \theta);$$

$$\tilde{y} = a^{-m}(-x \cos \theta + y \sin \theta).$$

Далее перечислены переменные, используемые в данном исследовании:

$$a = (U_h/U_l)^{\frac{1}{M-1}};$$

$$W_{m,n} = a^m U_l;$$

$$\sigma_{x,m,n} = \frac{(a+1)\sqrt{2\ln 2}}{2\pi a^m (a-1)U_l};$$

$$\sigma_{y,m,n} = \frac{1}{2\pi \operatorname{tg} \frac{\pi}{2N} \sqrt{\frac{U_h^2}{2\ln 2} - \left(\frac{1}{2\pi\sigma_{x,m,n}}\right)^2}}.$$

В нашей реализации используются следующие константы, которые также распространены в литературе: размер маски фильтра 60×60 , при этом $U_l = 0.05$; $U_h = 0.4$; s и t варьируются от 0 до 60.

1.5. Локальный бинарный шаблон (Local Binary Patterns – LBP) [46] рассчитывается путем сравнения одного пикселя с его соседями:

$$\text{LBP}_{Q,R} = \sum_{p=0}^{Q-1} s(g_p - g_c) 2^p;$$

$$s(x) = \begin{cases} 1, & x > 0; \\ 0, & x < 0, \end{cases}$$

где Q – общее количество задействованных соседей; R – радиус окрестности; g_c – значение серого центрального пикселя; g_q – значение его соседей. Если g_c имеет координаты $(0, 0)$, то g_q имеет координаты $(R \cos(2\pi q/Q), R \sin(2\pi q/Q))$. Значения серого соседей, которые не находятся в сетке изображения, могут быть аппроксимированы с помощью интерполяции. Предполагается, что изображение имеет размер $I \times J$. После обнаружения шаблона LBP каждого пикселя строится гистограмма для представления изображения текстуры:

$$H(k) = \sum_{i=1}^I \sum_{j=1}^J f[\text{LBP}_{Q,R}(i,j),k]; k \in [0,K];$$

$$f(x,y) = \begin{cases} 1, & x = y; \\ 0, & \text{otherwise.} \end{cases}$$

Максимальное значение шаблона LBP равно K . Значение U шаблона LBP представляет собой количество пространственных переходов (побитовые изменения 0/1):

$$U(\text{LBP}_{Q,R}) = |s(g_{Q-1} - g_c) - s(g_0 - g_c)| + \sum_{q=1}^{Q-1} |s(g_q - g_c) - s(g_{q-1} - g_c)|.$$

Равномерные паттерны LBP связаны с паттернами с ограниченным переходом или разрывами ($U \leq 2$) в круговом бинарном представлении. На практике для преобразования $\text{LBP}_{Q,R}$ в $\text{LBP}_{Q,R}^{u_2}$ (верхний индекс u_2 указывает однородные шаблоны с $U \leq 2$) используется таблица поиска $2Q$ элементов с $Q \times (Q-1) + 3$ различных выходных значений.

Чтобы получить инвариантность к вращению, локально инвариантный к вращению шаблон можно определить следующим образом:

$$\text{LBP}_{Q,R}^{\text{riu}_2} = \begin{cases} \sum_{q=0}^{Q-1} s(g_q - g_c), & U(\text{LBP}_{Q,R}) \leq 2; \\ Q+1, & \text{otherwise.} \end{cases}$$

Чтобы преобразовать $\text{LBP}_{Q,R}$ в $\text{LBP}_{Q,R}^{\text{riu}_2}$ (верхний индекс riu_2 (rotational invariance) указывает инвариантные к вращению "однородные"

шаблоны с $U \leq 2$), который имеет $Q + 2$ различных выходных значений, можно использовать таблицу поиска.

2. *Выбор признаков.* Если ω_1 и ω_2 – это два класса, которые в работе предназначены для определения пикселей с узлами и без узлов соответственно, а \mathbf{x} – это вектор признаков, выбираем ω_1 , если

$$P(\omega_1 | \mathbf{x}) > P(\omega_2 | \mathbf{x}),$$

вероятность ошибки зависит от разности $P(\omega_1 | \mathbf{x})$ и $P(\omega_2 | \mathbf{x})$. Таким образом, отношение $P(\omega_1 | \mathbf{x}) / P(\omega_2 | \mathbf{x})$ содержит полезные данные в области дискриминационных возможностей, связанных с принятым вектором признаков \mathbf{x} , относительно классов ω_1 и ω_2 . С другой стороны (для существующих значений $P(\omega_1 | \mathbf{x})$ и $P(\omega_2 | \mathbf{x})$), $\ln[P(\omega_1 | \mathbf{x}) / P(\omega_2 | \mathbf{x})] = D_{12}(\mathbf{x})$ также содержит ту же информацию и полезен для измерения базовой информации различения класса ω_1 относительно ω_2 . Логически $D_{12} = 0$ означает, что классы полностью перекрываются. Поскольку \mathbf{x} не является постоянным значением, рассматривается среднее значение по классу ω_1 :

$$D_{12} = \int_{-\infty}^{\infty} P(x | \omega_1) \ln \left[\frac{P(x | \omega_1)}{P(x | \omega_2)} \right] dx;$$

для класса ω_2 также имеются аналогичные рассуждения:

$$D_{21} = \int_{-\infty}^{\infty} P(x | \omega_2) \ln \left[\frac{P(x | \omega_2)}{P(x | \omega_1)} \right] dx,$$

сумма:

$$d_{12} = D_{12} + D_{21}. \quad (1)$$

Выявляются следующие свойства дивергенции:

$$d_{ij} \geq 0;$$

$$d_{ij} = 0, \text{ если } i = j;$$

$$d_{ij} = d_{ji}.$$

Формулу (1) можно использовать в качестве меры разделимости для классов ω_1 и ω_2 относительно \mathbf{x} (принятый вектор признаков), который известен как дивергенция. Все критерии, с

которыми мы имели дело до сих пор, измеряют способность классификации в отношении задачи двух классов. В мультиклассовой настройке $C(k)$ вычисляет форму среднего или "общего" значения. Для каждой пары классов использовалась и вычислялась одномерная дивергенция d_{ij} из [47]. Затем для каждой функции соответствующий $C(k)$ был установлен равным:

$$C(k) = \min_{i,j} d_{i,j}.$$

Вместо среднего значения $C(k)$ представляет собой наименьшее значение расхождения по всем парам классов. Таким образом, чтобы идентифицировать признаки с наилучшей способностью разделимости класса "наихудшего случая", необходимо использовать самые высокие значения $C(k)$. Работа с признаками по отдельности дает значительное преимущество с точки зрения простоты вычислений. Однако такие методы не учитывают существующие отношения между признаками.

Рассмотрим x_{nk} как k -й признак n -го шаблона с $n = 1, 2, \dots, N$ и $k = 1, 2, \dots, m$. Коэффициент взаимной корреляции между любыми двумя из них определяется выражением

$$\rho_{ij} = \frac{\sum_{n=1}^N x_{ni} x_{nj}}{\sqrt{\sum_{n=1}^N x_{ni}^2 \sum_{n=1}^N x_{nj}^2}}. \quad (2)$$

Можно продемонстрировать $|\rho_{ij}| \leq 1$. Этапы, из которых состоит процедура отбора, следующие:

1) выбор критерия отделимости класса C и вычисление его значения для всех заданных признаков x_k ; $k = 1, 2, \dots, m$. Затем результаты должны быть отсортированы в порядке возрастания, при этом лучшая функция получает наивысшее значение C . Другими словами, это x_{i1} ;

2) чтобы выбрать второй признак, вычисляют коэффициент взаимной корреляции, определенный в (2) между выбранным x_{i1} и всеми оставшимися $m - 1$ признаками, т. е. ρ_{ij} , $j \neq i$;

3) выбор функции x_{i2} , для которой

$$i_2 = \arg \max_j \left\{ \alpha_1 C(j) - \alpha_2 \left| \rho_{i_1 j} \right| \right\}; j \neq i_1,$$

где α_1 и α_2 определяют важность относительных или весовых коэффициентов, равных единице в данной работе. На практике для выбора следующего признака помимо меры отделимости класса C учитывается корреляция с ранее заданным признаком, после чего результаты обобщаются для k -го шага;

4) выбор x_{ik} ; $k = 3, \dots, l$ так, чтобы:

$$i_k = \arg \max_j \left\{ \alpha_1 C(j) - \frac{\alpha_2}{k-1} \sum_{r=1}^{k-1} \left| \rho_{i_r j} \right| \right\}, j \neq i_1. (3)$$

В (3) $r = 1, 2, \dots, k-1$. Также учитывалась средняя корреляция между всеми ранее выбранными признаками.

3. Модель обучения:

3.1. Конструкция модели. Статистические модели формы и текстуры (внешнего вида) делаются независимыми на основе выборок сегментации (обучающих данных) совокупности объектов, затем модели объединяются в единый ТАМ.

Моделирование формы: форма моделируется путем создания модели распределения x_s на основе ориентиров. Формы выравниваются в общую систему координат с помощью анализа Прокруста. Статистическая модель изменения формы может быть создана с использованием PCA (Principal Component Analysis) по контрольным точкам каждого N набора обучающих данных. Следующая линейная модель дает примеры изученного класса формы:

$$x = \bar{x} + \Omega_s b_s, (4)$$

где \bar{x} – среднее значение формы; Ω_s – специальная векторная матрица формы; b_s – параметр формы.

Моделирование текстуры: в конце преобразования изображений в градациях серого к средней форме с помощью схемы выборки сгенерирован вектор текстуры g для каждого экземпляра обучения. Нормирование интенсивности выполняется с умеренной интенсивностью 0 и дисперсией 1. Использование PCA в линейной модели нормальных данных для вектора интенсивности g может быть получено

$$g = \bar{g} + \Omega_g b_g,$$

где g – матрица собственного вектора интенсивности; \bar{g} – средняя интенсивность; Ω_g – матрица собственных векторов интенсивности; b_g – параметры интенсивности.

Комбинация формы и текстуры: для построения окончательной модели вектор коэффициентов формы b_s и вектор коэффициентов интенсивности уровня серого b_g соединяются следующим образом:

$$\begin{bmatrix} W_s b_s \\ b_g \end{bmatrix} = \begin{bmatrix} W_s \Omega_s^T (x - \bar{x}) \\ \Omega_g^T (g - \bar{g}) \end{bmatrix},$$

где W_s – диагональная матрица, относящаяся к различным единицам формы и интенсивности. Использование PCA для применения к выборке всех векторов b и представляет модель:

$$b = \Omega_c C = \begin{bmatrix} \Omega_{c,s} \\ \Omega_{c,g} \end{bmatrix} C, (5)$$

где Ω_c – матрица собственных векторов; C – результат коэффициентов модели внешнего вида.

3.2. Адаптация модели. ТАМ можно использовать для сегментации с помощью метода градиентного спуска. Параметры модели c и знак t определяют реальную форму в целевом кадре изображения. Пиксели, покрытые формой модели, преобразуются в рамку модели текстуры, чтобы соответствовать им. Этого можно добиться путем выборки пикселей по вектору интенсивности g_{im} и применения $B_u^{(-1)}$, в результате чего в кадре модели появится вектор интенсивности g_{im} .

Формулу (3) можно использовать для вычисления истинного значения уровня серого для модели g_{mo} (текстура текущей модели) из c . В процессе сопоставления остаточная L_2 -норма (the quadratic error measure) в (5) уменьшается путем корректировки вектора параметров в следующем выражении, которое состоит из параметров модели c , знака t и глобальных параметров интенсивности u :

$$\begin{aligned} r(p) &= g_{im}(p) - g_{mo}(p) = \\ &= B_u^{-1} [g_{im}(p)] - g_{mo}(p); \end{aligned} (6)$$

$$P^T = (c^T | t^T | u^T). (7)$$

Предполагается, что линейная зависимость между наблюдаемым оставшимся $r(p)$ и корректировкой параметра δ_p минимизирует ошибку при обновлении вектора параметров \mathbf{P} во время сопоставления. Методом самообучения изучается (7). В результате R рассматривается как константа, и пересчет на каждом шаге сопоставления избегается:

$$\delta_p = -Rr(p);$$

$$R = [J(r)^T J(r)]^{-1} J(r)^T,$$

где $J(r) = \frac{\delta r}{\delta p}$ – якобиан r .

ТАМ сопоставляется с целевым изображением путем повторения шагов 5–8 до тех пор, пока ошибка $\|r\|^2$ не уменьшится:

1) первоначально необходимо оценить все компоненты вектора параметров \mathbf{p}_0 : параметры модели c_0 (например, "средняя модель": $c_0 = 0$), параметры позы t_0 и параметры текстуры u_0 .

Установить $p = p_0$;

2) оценка остаточного вектора \mathbf{r} (см. (6));

3) вычисление текущей ошибки $E = \|\mathbf{r}\|^2$;

4) установка $k = 1$;

5) обновление вектора параметров: $\bar{\mathbf{p}} = \mathbf{p} + k\delta p = \mathbf{p} - kRr$;

6) вычисление нового вектора ошибки $\bar{\mathbf{r}}$ с помощью обновленного вектора параметров $\bar{\mathbf{p}}$;

7) если $(\|\bar{\mathbf{r}}\|)^2 \leq E$, то принимаются новые параметры: $p = \bar{p}$;

8) в противном случае необходимо пробовать $k = 1.5$; $k = 0.5$; $k = 0.25$ и т. д. и переходить к шагу 5.

Методы. *Классы легочных узлов.* Легкие представляют собой сложные органы с различными структурами, такими как щели, артерии, бронхи или плевра, которые могут прилегать к легочному узлу на трехмерной компьютерной томограмме. Узел в легком представляет собой каплеобразный объект типичной сфероидальной/эллипсоидальной формы с более светлыми пикселями, чем фон (легкие). В легких есть множество элементов разного размера, таких как бронхи и кровеносные вены, и их близость к узлам может иногда мешать обнаружению узлов и препятствовать их сегментации. Узелки делятся на четыре типа в зависимости от их расположения и отношения к окружающим структурам легкого (рис. 2): *a* – хорошо очерченные узелки: связи между этими узелками и другими легочными структурами нет; *б* – околососудистый узел: узел, расположенный рядом с сосудом, имеющий соединение с сосудом; *в* – с плевральным хвостом: узелки у стенки легкого, имеющие тонкое соединение со стенкой плевры. Плевральный хвост является частью узла. Это означает, что область сегментации должна включать этот хвост. В отличие от околососудистых узлов, неузелковую структуру нельзя вырезать, чтобы избежать недооценки фактического объема узла; *г* – околоплевральный узел: значительная часть поверхности околоплеврального узла прилегает к плевральной стенке. Из-за взаимосвязи между узлом и неузелковой структурой и геометрической формы окружающей неузелковой структуры




Рис. 2. Типы узелков в легких: *a* – хорошо очерченный узел; *б* – околососудистый узел;

в – узелки с плевральным хвостом; *г* – околоплевральный узел
Fig. 2. Lung nodule types: *a* – a well-defined nodule; *б* – a juxta-vascular nodule; *в* – nodules with pleural tail; *г* – a juxta-pleural nodule

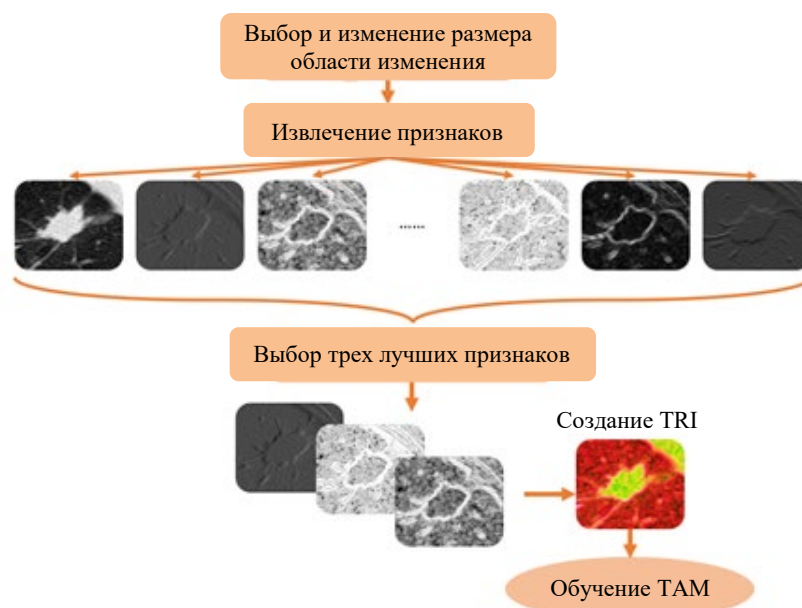


Рис. 3. Предлагаемая архитектура алгоритма

Fig. 3. Proposed algorithm architecture

околососудистые узелки отличаются от околососудистых узелков.

Сосуд может выглядеть как сферическая структура с трубчатой формой в структуре КТ. Плотность структуры легких и вен на КТ-изображении вполне сопоставима, и для их понимания требуются медицинские знания анатомии легких, включая расположение, форму, размер и связи между структурами легких. Алгоритм TAM предлагается в этой статье для эффективной сегментации всех видов упомянутых узелков.

Вычислительная стратегия. Реализация алгоритма TAM состоит из следующих основных этапов (рис. 3): извлечение признаков текстуры, выбор признаков, обучение модели внешнего вида текстуры и применение обученной модели к КТ-изображениям. В части обучения модель изучается с использованием изображений КТ и сегментации узлов, которые были выполнены врачами. Затем, чтобы проверить эффективность алгоритма, обученная модель применяется к входным КТ-изображениям, и результат сегментации сравнивается с результатом врачей. Этапы алгоритма обучения и применения рассматриваются следующим образом:

1) выбор области интереса: оператор выбирает интересующий узел на спиральных КТ-изображениях, используя пользовательский ком-

пьютерный интерфейс. Размер этой области составляет 50×50 пикселей, который затем будет изменен до 200×200 пикселей для дальнейшей обработки;

2) извлечение признаков текстуры: из области изменения размера извлекаются 129 различных текстурных и радиомических характеристик, включая Haralick, Grey, Grad, Gabor и LBP.

Выбор признака и создание TRI. Как указано, метод выбора выполняется с использованием следующих шагов:

1. На основе выбранного класса вычисляется критерий C для существующих признаков x_k ; $k = 1, 2, \dots, 129$. Затем результат следует ранжировать по убыванию и выбрать лучший признак с более высоким C . Можно сказать, что это x_{i_1} .

2. Второй признак должен быть выбран относительно коэффициента взаимной корреляции, который определен в (4) между каждым из оставшихся 128 признаков, и выбранным x_{i_1} .

3. Выбор функции x_{i_2} , для которой

$$i_2 = \arg \max_j \left\{ \alpha_1 C(j) - \alpha_2 |\rho_{i_1 j}| \right\}; j \neq i_1.$$

4. Выбор функции x_{i_3} , для которой

$$i_3 = \arg \max_j \left\{ \alpha_1 C(j) - \frac{\alpha_2}{2} |\rho_{i_1 j}| - \frac{\alpha_2}{2} |\rho_{i_2 j}| \right\},$$

где α_1, α_2 определяют относительную важность или вес. Здесь считается $\alpha_1 = \alpha_2 = 1$. Другими словами, при выборе следующего признака учитывалась не только мера отделимости класса C , но и корреляция с предыдущим признаком. В результате этого раздела из 129 текстурных признаков, извлеченных из легочного узла, были выбраны 3 лучших признака с высокой производительностью для создания текстурного представления изображения (TRI). Выбранными признаками являются Харалик, Грей и Лоу (рис. 4).

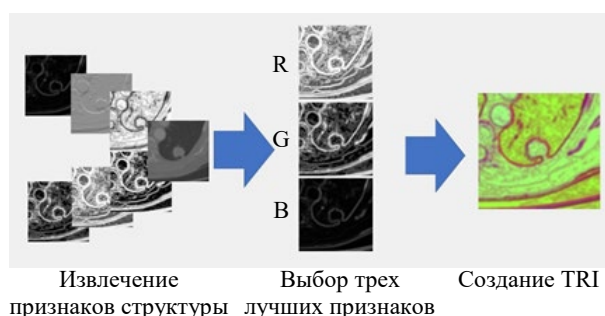


Рис. 4. Предлагаемая архитектура алгоритма

Fig. 4. Proposed algorithm architecture

Обучение модели включает следующие шаги:

1. Создание TRI: на основе 3 лучших признаков, создается RGB-изображение, в котором слой R является первым выбранным элементом, G и B – вторым и третьим признаками (рис. 4).

2. Выбор ориентира: для обучения ТАМ необходимо определить ориентиры в обучающих данных. Изучение надежного и точного метода автономного обнаружения ориентиров – сложная задача, которая имеет решающее значение для повышения точности алгоритма.

3. Обучение ТАМ. Модель обучена со следующими параметрами: количество точек контура, интерполированных между основными ориентирами, равно 80, размер текстуры внешнего вида как количество исходного изображения равен единице, количество масштабов изображения равно четырем, а количество итераций поиска равно 60. Для обучения ТАМ используются 50 TRI легочных узелков.

Применение обученной модели. Применение алгоритма состоит из четырех основных шагов:

1. Выбор и изменение размера области интереса: используя специализированный компьютерный пользовательский интерфейс, оператор

сначала выбирает интересующий узел на спиральных КТ-изображениях. Размер этой области составляет 50×50 пикселей, который затем будет изменен до 200×200 пикселей для дальнейшей обработки.

2. Извлечение признаков: 3 лучших признака, определенных на этапе обучения, извлекаются из области с измененным размером, включая Харалик, Грей, Лоу.

3. Создание начальной маски с использованием алгоритма Active Contour: чтобы начать применять изученную модель, модель с использованием изученных данных предлагает начальное приближение – ориентир для начала поиска узелка. В этой работе с использованием метода активного контура создается начальная маска узла, которая будет использоваться в качестве исходного ориентира для начала применения ТАМ.

4. Применение изученной модели: используются изученные параметры и начальная маска, созданная методом активного контура; исходная маска должна совпадать с областью узла при нажатии пользователем, после чего запускается алгоритм и выполняется поиск точной области узла.

Экспериментальные результаты. База данных. В экспериментах исследовали компьютерные томограммы легких из госпиталя Шариати (Иран). В этом исследовании использовался набор данных из 85 КТ-изображений с узлами в легких. Количество срезов на КТ-изображениях колебалось от 214 до 352, а толщина срезов составляла 1.5 мм. Пространственное разрешение $X-Y$ составляет 0.8850 ± 0.062 мм/пиксель (среднее значение \pm стандартное отклонение). Изображения КТ получают с помощью томографа "Сименс" с максимальным рабочим напряжением трубки до 120...140 кВ и током в диапазоне от 25 до 40 мА/с в зависимости от состояния пациента. Каждый срез имел планарное разрешение $XY 512 \times 512$ пикселей и 16-битное разрешение по шкале серого в единицах Хаунсфилда (HU).

Оценка модели. Оценка Dice (или F-оценка), точность, отзыв (или чувствительность), специфичность, частота ошибок, точность и частота ложных открытий (FDR) используются в данной статье для представления производительности предлагаемого алгоритма ТАМ.

По уравнению

$$\text{Dice} = \frac{2|e \cap g|}{|e| + |g|},$$

где e – площадь сегментированного узла на медицинском снимке с использованием компьютерных методов; g – площадь сегментированного узла по оценке врача-эксперта.

Кроме того, авторы использовали точность, чувствительность и специфичность для определения производительности этих алгоритмов:

$$\text{Точность} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN}};$$

$$\text{Чувствительность} = \frac{\text{TP}}{\text{TP} + \text{FN}};$$

$$\text{Специфичность} = \frac{\text{TN}}{\text{TN} + \text{FP}},$$

где TP – истинно положительное решение, которое принимает алгоритм; TN – истинно отрицательное решение; FP – ложноположительное решение; FN – ложноотрицательное решение.

Результат алгоритма. В клинических данных получение надежных данных для определения узловых границ является сложной задачей.

В табл. 2 представлены средние результаты предложенного алгоритма сегментации на 85 пациентах. Этот алгоритм также был реализован для изображений, содержащих гауссовский и спекл-шум. Сравнив результаты, можно считать, что алгоритм обладает высокой стабильностью при наличии различных шумов. На рис. 5 показано визуальное сравнение работы алгоритма и сегментации врачом-специалистом. Это сравнение свидетельствует о том, что предложенный алгоритм ТАМ, согласно вышеизложенному, обладает высокой устойчивостью на зашумленных изображениях и в случае удаления части изображения дает приемлемые результаты при сегментации.

На рис. 6 показаны результаты алгоритма по узлам в зависимости от их расположения в легких. Можно сделать вывод, что предложенный алгоритм обладает хорошей способностью отделять прикрепившийся к стенке легкого узел. Сле-

Табл. 2. Результаты использования ТАМ

Tab. 2. TAM performance

Тип	Precision	Sensitivity	Specificity	Error Rate	Dice	Accuracy	FDR
Без шума	86.56	97.84	88.25	88.24	84.75	96.27	13.375
Гауссовский шум	81.84	83.52	97.46	88.53	82.51	96.07	18.07
Спекл-шум	90.92	65.61	98.9	88.46	75.92	95.38	9




Рис. 5. Визуальные характеристики ТАМ по сравнению с сегментацией врачом (красная область – результат алгоритмов, а белая область – результат работы врачей): a – нормальная КТ; b – КТ с гауссовским шумом; v – КТ-сканирование со спекл-шумом

Fig. 5. TAM visual performance compared to segmentation by physicians (red area – obtained by algorithms and white area – obtained by physicians): a – normal CT scan; b – CT scan with Gaussian noise; v – CT scan with Speckle noise




Рис. 6. Результаты алгоритма TAM для узелков в соответствии с их расположением в легких
Fig. 6. TAM performance in nodule segmentation with respect to their location in the lungs

дует отметить, что при использовании предложенного алгоритма выделения узелков, прикрепленных к стенке легкого, нет необходимости отделять легкие от окружающих тканей. Однако, если используются алгоритмы Active Contour или Region Growing, для отделения узелков, прикрепленных к стенке легкого, сначала необходимо использовать алгоритм разделения легких, который может обнаруживать прикрепленные узелки.

Обсуждение. Как уже упоминалось, в последние годы возрос интерес к методам сегментации на основе моделей. Одним из преимуществ этих методов является то, что даже при потере некоторой информации об объекте такие пробелы можно заполнить, используя предыдущую информацию в модели. В этом разделе изучается производительность алгоритма TAM, Active Contour, Region Growing и комбинации алгоритмов Active Contour и Watershed. В табл. 3 представлены результаты реализации и тестирования этих четырех алгоритмов на компьютерных

томограммах легких. Согласно представленным результатам, предложенный алгоритм имеет лучшую производительность для сегментации узелков и более низкую частоту ложных срабатываний, что означает приемлемую стабильность алгоритма. Из-за близости комбинации алгоритмов Active Contour и Watershed на следующем этапе производительность этих четырех алгоритмов пересматривается путем добавления шума Гаусса и мультипликативного спекл-шума к КТ (табл. 3).

По полученным результатам, представленным в табл. 3, можно сделать вывод, что предложенный алгоритм на основе модели обладает устойчивостью к шуму. Устойчивость к шуму очень важна в алгоритмах сегментации, поскольку оценка объема опухоли и сегментация воспроизводимых и точных границ в медицинских изображениях важны для диагностики, определения стадии и оценки ответа на терапию рака. На рис. 7 показано видимое сравнение

Табл. 3. Оценка Dice реализации четырех алгоритмов сегментации в нормальной ситуации и при наличии шума

Tab. 3. Dice score characterizing the implementations of four segmentation algorithms under normal conditions and in the presence of noise

Dice	Active Contour	Region Growing	Watershed and Active Contour	TAM
Обычный	76.25	79.85	83.57	84.75
С гауссовским шумом ($\sigma = 0.05$)	46.42	35.84	59.71	82.51
Со спекл-шумом ($\sigma = 0.07$)	45.44	36.28	67.42	75.92




Рис. 7. Сравнение области сегментации алгоритмов сегментации при наличии спекл-шума (красная область – результат алгоритмов, а белая область – результат работы врачей): а – алгоритм ТАМ; б – активный контур и водораздел; в – регион выращивания; з – активный контур

Fig. 7. Comparison of the segmentation area obtained by segmentation algorithms in the presence of Speckle noise (red area – obtained by algorithms and white area – obtained by physicians): а – TAM algorithm; б – active contour and watershed; в – growing region; з – active contour

производительности этих четырех алгоритмов по отношению к удельному шуму, из которого можно сделать вывод, что алгоритм, представленный в статье, гораздо более устойчив к шуму.

Следующее сравнение между этими четырьмя алгоритмами проводится таким образом, чтобы исследовать точность алгоритмов сегментации узла в зависимости от местоположения узла в легком (рис. 8). Поскольку алго-

ритмы, полностью основанные на изображениях, не имеют возможности сегментировать узелки, прикрепленные к стенке легкого, перед использованием этих алгоритмов необходимо отделить легкое от окружающей области. Однако для отделения узелков, прикрепленных к стенке легкого, по представленному в статье алгоритму нет необходимости отделять легкое от окружающей области. Поэтому результаты отделения конкреций, прикрепленных к стене, по




Рис. 8. Сравнение производительности и стандартного отклонения алгоритмов сегментации

Fig. 8. Comparison of the performance and standard deviation of segmentation algorithms

этому алгоритму практически не уступают другим алгоритмам.

Согласно рис. 8, критерий Dice предлагаемого алгоритма выше, чем у других алгоритмов, однако критерий Dice во всех алгоритмах находится практически в одном диапазоне. Но существует большая разница в критерии частоты ложных открытий, т. е. представленный алгоритм на основе модели имеет минимальный критерий, который показывает мощность алгоритма в точной сегментации узелков. Кроме того, стандартное отклонение показателей сегментации на рис. 8 показывает, что предлагаемый метод обладает большей стабильностью при сегментации различных видов узлов.

Заключение. В статье представлен новый алгоритм для сегментации узелков в легком, который может сегментировать все типы узелков с вы-

сокой производительностью. Этот алгоритм основан на модели и вместе с алгоритмом активного контура способен повысить точность и устранить ложные срабатывания за счет определения начальной маски. Результаты сегментации легочных узелков на нормальном КТ-изображении следующие: precision 85.5, dice 85, accuracy 96 и specificity 98, что лучше, чем у алгоритма активного контура, алгоритма Region Growing и комбинации алгоритмов активного контура и Watershed. Кроме того, при наличии шума предложенный алгоритм получил следующий результат: precision 86, dice 80, accuracy 96 и specificity 98, что превосходит другие модели. Результаты работы показывают, что предложенный метод повышает точность деления узелков в легком и может помочь радиологам в интерпретации КТ-изображений, особенно для количественного анализа легкого.

Авторский вклад

Шариати Фаридоддин – анализ литературы, написание статьи.

Павлов Виталий Александрович – анализ литературы, написание статьи.

Завьялов Сергей Викторович – анализ результатов.

Махди Оруджи – разработка алгоритма анализа данных, сбор данных.

Первунина Татьяна Михайловна – сбор данных.

Author's contribution

Shariati Faridoddin, analyzed the literature, wrote the paper.

Vitalii A. Pavlov, analyzed the literature, wrote the paper.

Sergey V. Zavyalov, analyzed the results.

Mahdi Orooji, invented and developed a data analysis algorithm, collected data.

Tatyana M. Pervunina, collected data.

Список литературы

1. Texture appearance model, a new model-based segmentation paradigm, application on the segmentation of lung nodule in the CT scan of the chest / F. Shariaty, M. Orooji, E. N. Velichko, S. V. Zavjalov // Computers in biology and medicine. 2021. Vol. 140. P. 105086. doi: 10.1016/j.combiomed.2021.105086

2. Shariaty F., Mousavi M. Application of CAD systems for the automatic detection of lung nodules // Informatics in Medicine Unlocked. 2019. Vol. 15. P. 100173. doi: 10.1016/j.imu.2019.100173

3. Radiomics-based prognosis analysis for non-small cell lung cancer / Y. Zhang, A. Oikonomou, A. Wong, M. A. Haider, F. Khalvati // Scientific reports. 2017. Vol. 7, № 1. P. 1–8. doi: 10.1038/srep46349

4. HOSVD-based 3D active appearance model: segmentation of lung fields in CT images / Q. Wang, W. Kang, H. Hu, B. Wang // J. of Medical Systems. 2016. Vol. 40, № 7. P. 1–11. doi: 10.1007/s10916-016-0535-0

5. Cetin M., Iskurt A. An automatic 3-d reconstruction of coronary arteries by stereopsis // J. of medical systems. 2016. Vol. 40, № 4. P. 1–11. doi: 10.1007/s10916-016-0455-z

6. Automatic lung segmentation in computed tomography images using active shape model / F. Shariaty, M. Orooji, M. Mousavi, M. Baranov, E. Velichko // 2020 IEEE Intern. Conf. on Electrical Engineering and Photonics (EEExPolytech), St Petersburg, Russia, 15–16 Oct. 2020. Piscataway: IEEE, 2020. P. 156–159. doi: 10.1109/EEExPolytech50912.2020.9243982

7. Medical image segmentation by combining graph cuts and oriented active appearance models / X. Chen, J. K. Udupa, U. Bagci, Y. Zhuge, J. Yao // IEEE transactions on image processing. 2012. Vol. 21, № 4. P. 2035–2046. doi: 10.1109/TIP.2012.2186306

8. The performance of active-contour and region growing methods against noises in the segmentation of computed-tomography scans / M. Mousavi, F. Shariaty,

M. Orooji, E. Velichko // Book Chapter in Intern. Youth Conf. on Electronics, Telecommunications and Information Technologies. Springer, 2021. P. 573–582. doi: 10.1007/978-3-030-58868-7_63

9. Automated pulmonary nodule detection system in computed tomography images based on Active-contour and SVM classification algorithm / F. Shariaty, V. Davydov, V. Yushkova, A. Glinushkin, V. Y. Rud // J. of Physics: Conf. Series. 2019. Vol. 1410, № 1. P. 012075. doi: 10.1088/1742-6596/1410/1/012075

10. Shariaty F., Hosseinlou S., Rud V. Y. Automatic lung segmentation method in computed tomography scans // J. of Physics: Conf. Series, 2019. Vol. 1236, № 1. P. 012028. doi: 10.1088/1742-6596/1236/1/012028

11. Abdulameer M. H., Sheikh Abdullah S. N. H., Othman Z. A. A modified active appearance model based on an adaptive artificial bee colony // The Scientific World J. 2014. Vol. 2014. P. 1–16. doi: 10.1155/2014/879031

12. Automatic segmentation of thoracic and pelvic CT images for radiotherapy planning using implicit anatomic knowledge and organ-specific segmentation strategies / B. Haas, T. Coradi, M. Scholz, P. Kunz, M. Huber, U. Oppitz, L. André, V. Lengkeek, D. Huyskens, A. van Esch, R. Reddick // Physics in Medicine & Biology. 2008. Vol. 53, № 6. P. 1751–1771. doi: 10.1088/0031-9155/53/6/017

13. A new hybrid approach using fuzzy clustering and morphological operations for lung segmentation in thoracic CT images / S. P. Sahu, P. Agrawal, N. D. Londhe, S. Verma // Biomedical and Pharmacology J. 2017. Vol. 10, № 4. P. 1949–1961. doi: 10.13005/bpj/1315

14. Semi-automated segmentation of single and multiple tumors in liver CT images using entropy-based fuzzy region growing / A. Baâzaoui, W. Barhoumi, A. Ahmed, E. Zagrouba // IRBM. 2017. Vol. 38, № 2. P. 98–108. doi: 10.1016/j.irbm.2017.02.003

15. Kashyap R., Tiwari V. Active contours using global models for medical image segmentation // Intern. J. of Computational Systems Engineering. 2018. Vol. 4, № 2–3. P. 195–201. doi: 10.1504/IJCSYSE.2018.091404

16. Tabb A., Duncan K. E., Topp C. N. Segmenting root systems in X-ray computed tomography images using level sets // 2018 IEEE Winter Conf. on Applications of Computer Vision (WACV), Lake Tahoe, USA, 12–15 March 2018. IEEE, 2018. P. 586–595. doi: 10.1109/WACV.2018.00070

17. Marker-based watershed transform method for fully automatic mandibular segmentation from CBCT images / Y. Fan, R. Beare, H. Matthews, P. Schneider, N. Kilpatrick, J. Clement, P. Claes, A. Penington, C. Adamson // Dentomaxillofacial Radiology. 2019. Vol. 48, № 2. P. 20180261. doi: 10.1259/dmfr.20180261

18. Anter A. M., Hassenian A. E. CT liver tumor segmentation hybrid approach using neutrosophic sets, fast fuzzy c-means and adaptive watershed algorithm // Artificial intelligence in medicine. 2019. Vol. 97. P. 105–117. doi: 10.1016/j.artmed.2018.11.007

19. Pankaj A., Ayyappan S. Theoretical Concepts and Technical Aspects on Image Segmentation // Computer Vision: Concepts, Methodologies, Tools and Applications: IGI Global. 2018. P. 2333–2348.

20. A multi-view deep convolutional neural networks for lung nodule segmentation / S. Wang, M. Zhou, O. Gevaert, Z. Tang, D. Dong, Z. Liu, T. Jie // 2017 39th Annual Intern. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC), Jeju, Korea, 11–15 July 2017. IEEE, 2017. P. 1752–1755. doi: 10.1109/EMBC.2017.8037182

21. Roy R., Chakraborti T., Chowdhury A. S. A deep learning-shape driven level set synergism for pulmonary nodule segmentation // Pattern Recognition Lett. 2019. Vol. 123. P. 31–38. doi: 10.1016/j.patrec.2019.03.004

22. Fast and fully-automated detection and segmentation of pulmonary nodules in thoracic CT scans using deep convolutional neural networks / X. Huang, W. Sun, T.-L. B. Tseng, C. Li, W. Qian // Computerized Medical Imaging and Graphics. 2019. Vol. 74. P. 25–36. doi: 10.1016/j.compmedimag.2019.02.003

23. Mukherjee S., Huang X., Bhagalia R. R. Lung nodule segmentation using deep learned prior based graph cut // 2017 IEEE 14th Intern. Symp. on Biomedical Imaging (ISBI 2017), Melbourne, Australia, 18–21 Apr. 2017. IEEE, 2017. P. 1205–1208. doi: 10.1109/ISBI.2017.7950733

24. Hierarchical parsing and semantic navigation of full body CT data / S. Seifert, A. Barbu, S. K. Zhou, D. Liu, J. Feulner, M. Huber, M. Suehling, A. Cavallaro, D. Comaniciu // Proc. of SPIE. Medical Imaging 2009: Image Processing. 2009. Vol. 7259. P. 29–36. doi: 10.1117/12.812214

25. Stegmann M. B., Ersboll B. K., Larsen R. FAME-a flexible appearance modeling environment // IEEE Transactions on Medical Imaging. 2003. Vol. 22, № 10. P. 1319–1331. doi: 10.1109/TMI.2003.817780

26. Christensen G. E., Rabbitt R. D., Miller M. I. 3D brain mapping using a deformable neuroanatomy // Physics in Medicine & Biology. 1994. Vol. 39, № 3. P. 609–618. doi: 10.1088/0031-9155/39/3/022

27. Gordon G. G. Face recognition based on depth and curvature features // Proc. 1992 IEEE Computer Society Conf. on Computer Vision and Pattern Recognition. Champaign, USA, 15–18 June 1992. IEEE, 1992. P. 808–810. doi: 10.1109/CVPR.1992.223253

28. Sethuram A., Ricanek K., Patterson E. A comparative study of active appearance model annotation schemes for the face // Proc. of the Seventh Indian Conf. on Computer Vision, Graphics and Image Processing, 2010. P. 367–374. doi: 10.1145/1924559.1924608

29. Cootes T. F., Edwards G. J., Taylor C. J. Active appearance models // Proc. of European Conf. on Computer Vision. 1998. Vol. 2. P. 484–498.

30. Kamdi S., Krishna R. Image segmentation and region growing algorithm // Intern. J of Computer Technology and Electronics Engineering (IJCTEE). 2012. Vol. 2, № 1. P. 103–107.

31. Kass M., Witkin A., Terzopoulos D. Snakes: Active contour models // Intern. j. of computer vision. 1988. Vol. 1, № 4. P. 321–331.
32. Radiomics: extracting more features using endoscopic imaging / F. Shariaty, M. Baranov, E. Velichko, M. Galeeva, V. Pavlov // 2019 IEEE Intern. Conf. on Electrical Engineering and Photonics (EExPolytech). St Petersburg, Russia, 17–18 Oct. 2019. IEEE, 2019. P. 181–194. doi: 10.1109/EExPolytech.2019.8906843
33. Haralick R. M., Shanmugam K., Dinstein I. H. Textural features for image classification // IEEE Transactions on systems, man, and cybernetics. 1973. № 6. P. 610–621. doi: 10.1109/TSMC.1973.4309314
34. Punithavathy K., Ramya M., Poobal S. Analysis of statistical texture features for automatic lung cancer detection in PET/CT images // 2015 Intern. Conf. on Robotics, Automation, Control and Embedded Systems (RACE). Chennai, India, 18–20 Feb. 2015. IEEE, 2015. P. 1–5. doi: 10.1109/RACE.2015.7097244
35. Texture-based classification of focal liver lesions on MRI at 3.0 Tesla: A feasibility study in cysts and hemangiomas / Mayerhoefer M. E., Schima W., Trattnig S., Pinker K., Berger-Kulemann V., Ba-Ssalamah A. // J. of Magnetic Resonance Imaging. 2010. Vol. 32, № 2. P. 352–359. doi: 10.1002/jmri.22268
36. Computerized analysis of mammographic parenchymal patterns on a large clinical dataset of full-field digital mammograms: robustness study with two high-risk datasets / H. Li, M. L. Giger, L. Lan, J. B. Brown, A. MacMahon, M. Mussman, O. I. Olopade, C. Sennett // J. of digital imaging. 2012. Vol. 25, № 5. P. 591–598. doi: 10.1007/s10278-012-9452-z
37. Quantitative analysis of lesion morphology and texture features for diagnostic prediction in breast MRI / K. Nie, J.-H. Chen, J. Y. Hon, Y. Chu, O. Nalcioğlu, M.-Y. Su // Academic radiology. 2008. Vol. 15, № 12. P. 1513–1525. doi: 10.1016/j.acra.2008.06.005
38. Integrative analysis of DCE-MRI and gene expression profiles in construction of a gene classifier for assessment of hypoxia-related risk of chemoradiotherapy failure in cervical cancer / C. S. Fjeldbo, C. H. Julin, M. Lando, M. F. Forsberg, E.-K. Aarne, J. Alsner, G. B. Kristensen, E. Malinen, H. Lyng // Clinical Cancer Research. 2016. Vol. 22, № 16. P. 4067–4076. doi: 10.1158/1078-0432.CCR-15-2322
39. ADC texture – an imaging biomarker for high-grade glioma? / P. Brynolfsson, D. Nilsson, R. Henriksen, J. Hauksson, M. Karlsson, A. Garpebring, R. Birkander, J. Trygg, T. Nyholm, T. Askund // Medical physics. 2014. Vol. 41, № 10. P. 101903. doi: 10.1118/1.4894812
40. Radiomics: extracting more information from medical images using advanced feature analysis / P. Lambin, E. Rios-Velazquez, R. Leijenaar, S. Carvalho, R. G. P. M. van Stiphout, P. Granton, C. M. L. Zegers, R. Gillies, R. Boellard, A. Dekker, H. J. W. L. Aerts // European j. of cancer. 2012. Vol. 48, № 4. P. 441–446. doi: 10.1016/j.ejca.2011.11.036
41. Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach / H. J. W. L. Aerts, E. R. Velazquez, R. T. H. Leijenaar, C. Parmar, P. Grossmann, S. Carvalho, J. Bussink, R. Monshouwer, B. Haibe-Kains, D. Rietveld, F. Hoebers, M. M. Rietbergen, C. R. Leemans, A. Dekker, J. Quackenbush, R. J. Gillies, P. Lambin // Nature communications. 2014. Vol. 5, № 1. P. 1–9. doi: 10.1038/ncomms5006
42. FDG PET/CT radiomics for predicting the outcome of locally advanced rectal cancer / P. Lovinfosse, M. Polus, D. V. Daele, P. Martinive, F. Daenen, M. Hatt, D. Visvikis, B. Koopmansch, F. Lambert, C. Coimbra, L. Seidel, A. Albert, P. Delvenne, R. Hustinx // European j. of nuclear medicine and molecular imaging. 2018. Vol. 45, № 3. P. 365–375. doi: 10.1007/s00259-017-3855-5
43. Cho H.-h., Park H. Classification of low-grade and high-grade glioma using multi-modal image radiomics features // 2017 39th Annual Intern. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC). Jeju, Korea, 11–15 July 2017. IEEE, 2017. P. 3081–3084. doi: 10.1109/EMBC.2017.8037508
44. Al-Kilidar S. H., George L. E. Texture classification using gradient features with artificial neural network // J. of Southwest Jiaotong University. 2022. Vol. 55, № 1. doi: 10.35741/issn.0258-2724.55.1.13
45. Smith J. R. Integrated spatial and feature image systems: Retrieval, analysis and compression. Columbia University, 1997. 178 p.
46. Ojala T., Pietikainen M., Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns // IEEE Transactions on pattern analysis and machine intelligence. 2002. Vol. 24, № 7. P. 971–987. doi: 10.1109/TPAMI.2002.1017623
47. Su K.-Y., Lee C.-H. Speech recognition using weighted HMM and subspace projection approaches // IEEE transactions on speech and audio processing. 1994. Vol. 2, № 1. P. 69–79. doi: 10.1109/89.260336

Информация об авторах

Шариати Фаридоддин – магистр (2021), ассистент (2021) Высшей школы прикладной физики и космических технологий Санкт-Петербургского политехнического университета Петра Великого. Автор более 10 научных работ. Сфера научных интересов – обработка изображений; обработка сигналов; компьютерное зрение; машинное обучение.

Адрес: Санкт-Петербургский политехнический университет Петра Великого, ул. Политехническая, д. 29, Санкт-Петербург, 195251, Россия
E-mail: shariati2.f@edu.spbstu.ru
<https://orcid.org/0000-0002-7060-8826>

Павлов Виталий Александрович – кандидат технических наук (2020), ассистент (2021) Высшей школы прикладной физики и космических технологий Санкт-Петербургского политехнического университета Петра Великого. Научный сотрудник Центра персонализированной медицины Национального медицинского исследовательского центра им. В. А. Алмазова. Автор более 40 научных работ. Сфера научных интересов – обработка сигналов; обработка изображений; компьютерное зрение; машинное обучение; глубокое обучение. Адрес: Санкт-Петербургский политехнический университет Петра Великого, ул. Политехническая, д. 29, Санкт-Петербург, 195251, Россия
E-mail: pavlov_va@spbstu.ru
<https://orcid.org/0000-0003-0726-6613>

Завьялов Сергей Викторович – кандидат технических наук (2015), доцент (2020) Высшей школы прикладной физики и космических технологий Санкт-Петербургского политехнического университета Петра Великого. Автор более 90 научных работ. Сфера научных интересов – обработка сигналов; обработка изображений. Адрес: Санкт-Петербургский политехнический университет Петра Великого, ул. Политехническая, д. 29, Санкт-Петербург, 195251, Россия
E-mail: zavyalov_sv@spbstu.ru
<https://orcid.org/0000-0003-3398-3616>

Махди Оруджи – Ph.D. (2012) в области электротехники по специальности "Системы связи", Университет штата Луизиана (Батон-Руж, Луизиана, США). Приглашенный профессор Калифорнийского университета (США, Дэвис). Автор более 70 научных работ. Сфера научных интересов – обработка изображений; обработка сигналов; компьютерное зрение; машинное обучение. Адрес: Калифорнийский университет, 1 Shields Ave, Дэвис, Калифорния 95616, США
E-mail: morooji@gmail.com
<https://orcid.org/0000-0003-1129-0667>

Первунина Татьяна Михайловна – доктор медицинских наук (2019), доцент (2015) Национального медицинского исследовательского центра им. В. А. Алмазова. Автор более 100 научных работ. Сфера научных интересов – персонализированные программы в ведении пациентов с врожденными пороками сердечно-сосудистой и мочевой систем; изучение кардиоренального синдрома в периоде и возможностей нефропротективной терапии в детской возрастной группе; компьютерная томография. Адрес: Национальный медицинский исследовательский центр им. В. А. Алмазова, ул. Аккуратова, д. 2, Санкт-Петербург, 197341, Россия
E-mail: ptm.pervunina@yandex.ru
<https://orcid.org/0000-0001-9948-7303>

References

1. Shariaty F., Orooji M., Velichko E. N., Zavjalov S. V. Texture Appearance Model, a New Model-Based Segmentation Paradigm, Application on the Segmentation of Lung Nodule in the CT Scan of the Chest. *Computers in Biology and Medicine*. 2021, vol. 140, p. 105086. doi: 10.1016/j.compbiomed.2021.105086
2. Shariaty F., Mousavi M. Application of CAD Systems for the Automatic Detection of Lung Nodules. *Informatics in Medicine Unlocked*. 2019, vol. 15, p. 100173. doi: 10.1016/j.imu.2019.100173
3. Zhang Y., Oikonomou A., Wong A., Haider M. A., Khalvati F. Radiomics-Based Prognosis Analysis for Non-Small Cell Lung Cancer. *Scientific Reports*. 2017, vol. 7, no. 1, pp. 1–8. doi: 10.1038/srep46349
4. Wang Q., Kang W., Hu H., Wang B. HOSVD-Based 3D Active Appearance Model: Segmentation of Lung Fields in CT Images. *J. of Medical Systems*. 2016, vol. 40, no. 7, pp. 1–11. doi: 10.1007/s10916-016-0535-0
5. Cetin M., Iskurt A. An Automatic 3-d Reconstruction of Coronary Arteries by Stereopsis. *J. of Medical Systems*. 2016, vol. 40, no. 4, pp. 1–11. doi: 10.1007/s10916-016-0455-z
6. Shariaty F., Orooji M., Mousavi M., Baranov M., Velichko E. Automatic Lung Segmentation in Computed Tomography Images Using Active Shape Model. 2020 IEEE Intern. Conf. on Electrical Engineering and Photonics (EExPolytech), St Petersburg, Russia, 15–16 Oct. 2020. Piscataway, IEEE, 2020, pp. 156–159. doi: 10.1109/EExPolytech50912.2020.9243982
7. Chen X., Udupa J. K., Bagci U., Zhuge Y., Yao J. Medical Image Segmentation by Combining Graph Cuts and Oriented Active Appearance Models. *IEEE transactions on image processing*. 2012, vol. 21, no. 4, pp. 2035–2046. doi: 10.1109/TIP.2012.2186306
8. Mousavi M., Shariaty F., Orooji M., Velichko E. The Performance of Active-Contour and Region Growing Methods Against Noises in the Segmentation of Computed-Tomography Scans. Book Chapter in Intern. Youth Conf. on Electronics, Telecommunications and Information Technologies. Springer, 2021, pp. 573–582. doi: 10.1007/978-3-030-58868-7_63
9. Shariaty F., Davydov V., Yushkova V., Glinushkin A., Rud V. Y. Automated Pulmonary Nodule Detection System in Computed Tomography Images Based on Active-Contour and SVM Classification Algorithm. *J. of*

Physics: Conf. Series. 2019, vol. 1410, no. 1, p. 012075. doi: 10.1088/1742-6596/1410/1/012075

10. Shariaty F., Hosseinlou S., Rud V. Y. Automatic Lung Segmentation Method in Computed Tomography Scans. *J. of Physics: Conf. Series*, 2019, vol. 1236, no. 1, p. 012028. doi: 10.1088/1742-6596/1236/1/012028

11. Abdulameer M. H., Sheikh Abdullah S. N. H., Othman Z. A. A Modified Active Appearance Model Based on an Adaptive Artificial Bee Colony. *The Scientific World J.* 2014, vol. 2014. doi: 10.1155/2014/879031

12. Haas B., Coradi T., Scholz M., Kunz P., Huber M., Oppitz U., André L., Lengkeek V., Huyskens D., van Esch A., Reddick R. Automatic Segmentation of Thoracic and Pelvic CT Images for Radiotherapy Planning Using Implicit Anatomic Knowledge and Organ-Specific Segmentation Strategies. *Physics in Medicine & Biology*. 2008, vol. 53, no. 6, pp. 1751–1771. doi: 10.1088/0031-9155/53/6/017

13. Sahu S. P., Agrawal P., Londhe N. D., Verma S. A. New Hybrid Approach Using Fuzzy Clustering and Morphological Operations for Lung Segmentation in Thoracic CT Images. *Biomedical and Pharmacology J.* 2017, vol. 10, no. 4, pp. 1949–1961. doi: 10.13005/bpj/1315

14. Baâzaoui A., Barhoumi W., Ahmed A., Zagrouba E. Semi-Automated Segmentation of Single and Multiple Tumors in Liver CT Images Using Entropy-Based Fuzzy Region Growing. *IRBM*. 2017, vol. 38, no. 2, pp. 98–108. doi: 10.1016/j.irbm.2017.02.003

15. Kashyap R., Tiwari V. Active Contours Using Global Models for Medical Image Segmentation. *Intern. J. of Computational Systems Engineering*. 2018, vol. 4, no. 2–3, pp. 195–201. doi: 10.1504/IJCSYSE.2018.091404

16. Tabb A., Duncan K. E., Topp C. N. Segmenting Root Systems in X-ray Computed Tomography Images Using Level Sets. 2018 IEEE Winter Conf. on Applications of Computer Vision (WACV), Lake Tahoe, USA, 12–15 March 2018. IEEE, 2018, pp. 586–595. doi: 10.1109/WACV.2018.00070

17. Fan Y., Beare R., Matthews H., Schneider P., Kilpatrick N., Clement J., Claes P., Penington A., Adamson C. Marker-Based Watershed Transform Method for Fully Automatic Mandibular Segmentation from CBCT Images. *Dentomaxillofacial Radiology*. 2019, vol. 48, no. 2, p. 20180261. doi: 10.1259/dmfr.20180261

18. Anter A. M., Hassenian A. E. CT Liver Tumor Segmentation Hybrid Approach Using Neutrosophic Sets, Fast Fuzzy C-Means and Adaptive Watershed Algorithm. *Artificial Intelligence in Medicine*. 2019, vol. 97, pp. 105–117. doi: 10.1016/j.artmed.2018.11.007

19. Pankaj A., Ayyappan S. Theoretical Concepts and Technical Aspects on Image Segmentation. *Computer Vision: Concepts, Methodologies, Tools and Applications*: IGI Global. 2018, pp. 2333–2348.

20. Wang S., Zhou M., Gevaert O., Tang Z., Dong D., Liu Z., Jie T. A Multi-View Deep Convolutional Neural Networks for Lung Nodule Segmentation. 2017 39th Annual Intern. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC), Jeju, Korea, 11–15 July

2017. IEEE, 2017, pp. 1752–1755. doi: 10.1109/EMBC.2017.8037182

21. Roy R., Chakraborti T., Chowdhury A. S. A Deep Learning-Shape Driven Level Set Synergism for Pulmonary Nodule Segmentation. *Pattern Recognition Letters*. 2019, vol. 123, pp. 31–38. doi: 10.1016/j.patrec.2019.03.004

22. Huang X., Sun W., Tseng T.-L. B., Li C., Qian W. Fast and Fully-Automated Detection and Segmentation of Pulmonary Nodules in Thoracic CT Scans Using Deep Convolutional Neural Networks. *Computerized Medical Imaging and Graphics*. 2019, vol. 74, pp. 25–36. doi: 10.1016/j.compmedimag.2019.02.003

23. Mukherjee S., Huang X., Bhagalia R. R. Lung Nodule Segmentation Using Deep Learned Prior Based Graph Cut. 2017 IEEE 14th Intern. Symp. on Biomedical Imaging (ISBI 2017), Melbourne, Australia, 18–21 April 2017. IEEE, 2017, pp. 1205–1208. doi: 10.1109/ISBI.2017.7950733

24. Seifert S., Barbu A., Zhou S. K., Liu D., Feulner J., Huber M., Suehling M., Cavallaro A., Comaniciu D. Hierarchical Parsing And Semantic Navigation of Full Body CT Data. *Proc. of SPIE. Medical Imaging 2009: Image Processing*. 2009, vol. 7259, pp. 29–36. doi: 10.1117/12.812214

25. Stegmann M. B., Ersboll B. K., Larsen R. FAME-a Flexible Appearance Modeling Environment. *IEEE Transactions on Medical Imaging*. 2003, vol. 22, no. 10, pp. 1319–1331. doi: 10.1109/TMI.2003.817780

26. Christensen G. E., Rabbitt R. D., Miller M. I. 3D Brain Mapping Using a Deformable Neuroanatomy. *Physics in Medicine & Biology*. 1994, vol. 39, no. 3, pp. 609–618. doi: 10.1088/0031-9155/39/3/022

27. Gordon G. G. Face Recognition Based on Depth and Curvature Features. *Proc. 1992 IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*. Champaign, USA, 15–18 June 1992. IEEE, 1992, pp. 808–810. doi: 10.1109/CVPR.1992.223253

28. Sethuram A., Ricanek K., Patterson E. A Comparative Study of Active Appearance Model Annotation Schemes for the Face. *Proc. of the Seventh Indian Conf. on Computer Vision, Graphics and Image Processing*. 2010, pp. 367–374. doi: 10.1145/1924559.1924608

29. Cootes T. F., Edwards G. J., Taylor C. J. Active Appearance Models. *Proc. of European Conf. on Computer Vision*. 1998, vol. 2, pp. 484–498.

30. Kamdi S., Krishna R. Image Segmentation and Region Growing Algorithm. *Intern. J. of Computer Technology and Electronics Engineering (IJCTEE)*. 2012, vol. 2, no. 1, pp. 103–107.

31. Kass M., Witkin A., Terzopoulos D. Snakes: Active Contour Models. *Intern. J. of Computer Vision*. 1988, vol. 1, no. 4, pp. 321–331.

32. Shariaty F., Baranov M., Velichko E., Galeeva M., Pavlov V. Radiomics: Extracting More Features Using Endoscopic Imaging. 2019 IEEE Intern. Conf. on Electrical Engineering and Photonics (EExPolytech). St. Petersburg, Russia, 17–18 Oct. 2019. IEEE, 2019, pp. 181–194. doi: 10.1109/EExPolytech.2019.8906843

33. Haralick R. M., Shanmugam K., Dinstein I. H. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*. 1973, no. 6, pp. 610–621. doi: 10.1109/TSMC.1973.4309314
34. Punithavathy K., Ramya M., Poobal S. Analysis of Statistical Texture Features for Automatic Lung Cancer Detection in PET/CT Images. 2015 Intern. Conf. on Robotics, Automation, Control and Embedded Systems (RACE). Chennai, India, 18–20 Feb. 2015. IEEE, 2015, pp. 1–5. doi: 10.1109/RACE.2015.7097244
35. Mayerhoefer M. E., Schima W., Trattnig S., Pinker K., Berger-Kulemann V., Ba-Ssalamah A. Texture-Based Classification of Focal Liver Lesions on MRI at 3.0 Tesla: A Feasibility Study in Cysts and Hemangiomas. *J. of Magnetic Resonance Imaging*. 2010, vol. 32, no. 2, pp. 352–359. doi: 10.1002/jmri.22268
36. Li H., Giger M. L., Lan L., Brown J. B., MacMahon A., Musshman M., Olopade O. I., Sennett C. Computerized Analysis of Mammographic Parenchymal Patterns on a Large Clinical Dataset of Full-Field Digital Mammograms: Robustness Study With Two High-Risk Datasets. *J. of Digital Imaging*. 2012, vol. 25, no. 5, pp. 591–598. doi: 10.1007/s10278-012-9452-z
37. Nie K., Chen J.-H., Hon J. Y., Chu Y., Nalcioğlu O., Su M.-Y. Quantitative Analysis of Lesion Morphology and Texture Features for Diagnostic Prediction in Breast MRI. *Academic Radiology*. 2008, vol. 15, no. 12, pp. 1513–1525. doi: 10.1016/j.acra.2008.06.005
38. Fjeldbo C. S., Julin C. H., Lando M., Forsberg M. F., Aarne E.-K., Alsner J., Kristensen G. B., Malinen E., Lyng H. Integrative Analysis of DCE-MRI and Gene Expression Profiles in Construction of a Gene Classifier for Assessment of Hypoxia-Related Risk of Chemoradiotherapy Failure in Cervical Cancer. *Clinical Cancer Research*. 2016, vol. 22, no. 16, pp. 4067–4076. doi: 10.1158/1078-0432.CCR-15-2322
39. Brynolfsson P., Nilsson D., Henriksson R., Hauksson J., Karlsson M., Garpebring A., Birgander R., Trygg J., Nyholm T., Askund T. ADC Texture – an Imaging Biomarker for High-Grade Glioma? *Medical Physics*. 2014, vol. 41, no. 10, p. 101903. doi: 10.1118/1.4894812
40. Lambin P., Rios-Velazquez E., Leijenaar R., Carvalho S., van Stiphout R. G. P. M., Granton P., Zegers C. M. L., Gillies R., Boellard R., Dekker A., Aerts H. J. W. L. Radiomics: Extracting More Information from Medical Images Using Advanced Feature Analysis. *European J. of Cancer*. 2012, vol. 48, no. 4, pp. 441–446. doi: 10.1016/j.ejca.2011.11.036
41. Aerts H. J. W. L., Velazquez E. R., Leijenaar R. T. H., Parmar C., Grossmann P., Carvalho S., Bussink J., Monshouwer R., Haibe-Kains B., Rietveld D., Hoebers F., Rietbergen M. M., Leemans C. R., Dekker A., Quackenbush J., Gillies R. J., Lambin P. Decoding Tumour Phenotype by Noninvasive Imaging Using a Quantitative Radiomics Approach. *Nature Communications*. 2014, vol. 5, no. 1, pp. 1–9. doi: 10.1038/ncomms5006
42. Lovinfosse P., Polus M., Daele D. V., Martinive P., Daenen F., Hatt M., Visvikis D., Koopmansch B., Lambert F., Coimbra C., Seidel L., Albert A., Delvenne P., Hustinx R. FDG PET/CT Radiomics for Predicting the Outcome of Locally Advanced Rectal Cancer. *European J. of Nuclear Medicine and Molecular Imaging*. 2018, vol. 45, no. 3, pp. 365–375. doi: 10.1007/s00259-017-3855-5
43. Cho H.-h., Park H. Classification of Low-Grade and High-Grade Glioma Using Multi-Modal Image Radiomics Features. 2017 39th Annual Intern. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC). Jeju, Korea, 11–15 July 2017. IEEE, 2017, pp. 3081–3084. doi: 10.1109/EMBC.2017.8037508
44. Al-Kilidar S. H., George L. E. Texture Classification Using Gradient Features with Artificial Neural Network. *J. of Southwest Jiaotong University*. 2022, vol. 55, no. 1. doi: 10.35741/issn.0258-2724.55.1.13
45. Smith J. R. Integrated Spatial And Feature Image Systems: Retrieval, Analysis and Compression. Columbia University, 1997, 178 p.
46. Ojala T., Pietikainen M., Maenpää T. Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2002, vol. 24, no. 7, pp. 971–987. doi: 10.1109/TPAMI.2002.1017623
47. Su K.-Y., Lee C.-H. Speech Recognition Using Weighted HMM and Subspace Projection Approaches. *IEEE Transactions on Speech and Audio Processing*. 1994, vol. 2, no. 1, pp. 69–79. doi: 10.1109/89.260336

Information about the authors

Shariati Faridoddin, Master in "Electrical engineering" (2021), Assistant (2021) of the Higher School of Applied Physics and Space Technologies of Peter the Great St. Petersburg Polytechnic University. The author of more than 15 scientific publications. Area of expertise: signal processing; image processing; computer vision; machine learning. Address: Peter the Great St. Petersburg Polytechnic University, 29 Politekhnicheskaya St., St Petersburg 195251, Russia E-mail: shariati2.f@edu.spbstu.ru <https://orcid.org/0000-0002-7060-8826>

Vitalii A. Pavlov, Cand. Sci. (Eng.) (2020), Assistant (2021) of the Higher School of Applied Physics and Space Technologies of Peter the Great St. Petersburg Polytechnic University. Researcher of Center for Personalized Medicine of Almazov National Medical Research Centre. The author of more than 40 scientific publications. Area of expertise: signal processing; image processing; computer vision; machine learning, deep learning. Address: Peter the Great St. Petersburg Polytechnic University, 29 Politekhnicheskaya St., St Petersburg 195251, Russia E-mail: pavlov_va@spbstu.ru <https://orcid.org/0000-0003-0726-6613>

Sergey V. Zavyalov, Cand. Sci. (Eng.) (2015), Associate Professor (2020) of the Higher School of Applied Physics and Space Technologies of Peter the Great St. Petersburg Polytechnic University. The author of more than 90 scientific publications. Area of expertise: signal processing; image processing.
Address: Peter the Great St. Petersburg Polytechnic University, 29 Politekhnicheskaya St., St Petersburg 195251, Russia
E-mail: zavyalov_sv@spbstu.ru
<https://orcid.org/0000-0003-3398-3616>

Mahdi Orooji, Ph.D. (2012) in electrical engineering with a degree in communications systems from Louisiana State University, Baton Rouge, Louisiana, USA. Visiting Professor at the University of California, USA, Davis. The author of more than 70 scientific publications. Area of expertise: signal processing, image processing, computer vision, machine learning.
Address: University of California, 1 Shields Ave, Davis, CA 95616, United States
E-mail: morooji@gmail.com
<https://orcid.org/0000-0003-1129-0667>

Tatyana M. Pervunina, Dr Sci. (Medicine) (2019), Associate Professor (2015) of Almazov National Medical Research Centre. The author of over 100 scientific publications. Area of expertise: personalized programs in the management of patients with congenital malformations of the cardiovascular and urinary systems; the study of cardiorenal syndrome in the period and the possibilities of nephroprotective therapy in the pediatric age group; computed tomography.
Address: Almazov National Medical Research Centre, 2 Akkuratova St., St Petersburg 197341, Russia.
E-mail: ptn.pervunina@yandex.ru
<https://orcid.org/0000-0001-9948-7303>
