

ISSN 2077-6810

ПЕРСПЕКТИВЫ НАУКИ

SCIENCE PROSPECTS

№ 5(128) 2020

Главный редактор

Воронкова О.В.

Редакционная коллегия:

Шувалов В.А.

Алтухов А.И.

Воронкова О.В.

Омар Ларук

Тютюнник В.М.

Вербицкий А.А.

Беднаржевский С.С.

Чамсутдинов Н.У.

Петренко С.В.

Леванова Е.А.

Осипенко С.Т.

Надточий И.О.

Ду Кунь

У Сунцзе

Бережная И.Ф.

Даукаев А.А.

Дривотин О.И.

Запивалов Н.П.

Пухаренко Ю.В.

Пеньков В.Б.

Джаманбалин К.К.

Даниловский А.Г.

Иванченко А.А.

Шадрин А.Б.

Снежко В.Л.

Левшина В.В.

Мельникова С.И.

Артюх А.А.

Лифинцева А.А.

Попова Н.В.

Серых А.Б.

Учредитель

**МОО «Фонд развития
науки и культуры»**

В ЭТОМ НОМЕРЕ:

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ:

Системный анализ, управление
и обработка информации

Автоматизация и управление

Вычислительные машины, комплексы и
компьютерные сети

Математическое моделирование и
численные методы

СТРОИТЕЛЬСТВО И АРХИТЕКТУРА:

Строительные конструкции,
здания и сооружения

Технология и организация строительства

Архитектура, реставрация и реконструкция

Градостроительство

ПЕДАГОГИЧЕСКИЕ НАУКИ:

Теория и методика обучения и воспитания

Физическое воспитание
и физическая культура

Профессиональное образование

ТАМБОВ 2020

Содержание

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

Системный анализ, управление и обработка информации

- Воробьев С.П., Широбокова С.Н., Евсин В.А.** Модель архитектуры системы распределенного реестра в среде облачных и туманных вычислений..... 10
- Жалыбин А.А.** Классификация текста с помощью нейронных сетей..... 14
- Махасин Али Абделрахман Фрах** Многоисточник индекса электромагнитного загрязнения и его влияние на здоровье человека 18
- Соловьева С.Н., Рычков Д.А.** Разработка модели определения структуры патологии при онкологической диагностике легких 21

Автоматизация и управление

- Истратова Е.Е., Син Д.Д., Строкин К.Б.** Разработка информационной системы для сбора и обработки Big Data в строительстве..... 29
- Шегельман И.Р., Васильев А.С., Шадрин А.А.** Расширение функциональных возможностей лесопосадочной машины..... 36

Вычислительные машины, комплексы и компьютерные сети

- Лушпа Е.Ю.** Локальные вычислительные сети. Особенности и методы построения..... 39

Математическое моделирование и численные методы

- Паранук А.А., Хрисониди В.А., Схаляхо З.Ч., Подлесный Д.С., Степанов М.С.** Разработка математической модели расчета адсорбций бинарных растворов посредством языка C++ .. 45

СТРОИТЕЛЬСТВО И АРХИТЕКТУРА

Строительные конструкции, здания и сооружения

- Свинарев В.С., Шульженко Е.В., Горбунова Е.С.** Нанокерамический порошок в роли мелкого заполнителя в бетонной смеси 51
- Сканави Н.А.** Использование дисперсных отходов металлообработки в производстве строительной керамики 54
- Харин Ю.И.** Выбор оптимальных вариантов свайных фундаментов в прибрежных районах Вьетнама и Туниса..... 58

Технология и организация строительства

- Клыков М.С., Григорьев Н.П., Сульдин А.Н.** Прогнозирование спроса на материальные ресурсы при строительстве мостов 62

РАЗРАБОТКА МОДЕЛИ ОПРЕДЕЛЕНИЯ СТРУКТУРЫ ПАТОЛОГИИ ПРИ ОНКОЛОГИЧЕСКОЙ ДИАГНОСТИКЕ ЛЕГКИХ

С.Н. СОЛОВЬЕВА, Д.А. РЫЧКОВ

*ФГАОУ ВО «Уральский федеральный университет
имени Первого Президента России Б.Н. Ельцина»,
г. Екатеринбург*

Ключевые слова и фразы: анализ; классификация; компьютерная томография (КТ); моделирование; обработка; структура; текстурная сегментация.

Аннотация: В работе рассматривается задача структурного анализа патологий легких на КТ-изображениях и проблема неприменимости существующих алгоритмов обработки и анализа изображений для дифференциальной диагностики легочных патологий. Сформулированы и проанализированы проблемы, обусловленные структурной сложностью патологий легких. Предложена концепция модели определения структуры патологий легких на основе КТ-изображений, включающая современные методы сегментации и фрактального анализа изображений и позволяющая учитывать текстурные особенности изображений легочных патологий. Осуществлен литературно-аналитический обзор методов сегментации изображений, методов извлечения текстурных признаков и методов классификации. Установлены критерии оценки алгоритмов и выявлены критерии оценки модели определения структуры патологий легких. Разработан пакет алгоритмических, функциональных и математических моделей, позволяющий проиллюстрировать новизну предлагаемого нами решения. Полученная в результате модель позволяет определить структуру патологии при онкологической диагностике легких и увеличивает точность дифференцирования патологии легких на КТ-изображениях с учетом классификационных признаков.

Ежегодно в мире выявляется более 10 миллионов случаев онкологических заболеваний, а смертность достигает 20 % [1]. По прогнозам Всемирной организации здравоохранения, к 2040 г. на 20 миллионов новых заболевших будет приходиться 12 миллионов смертей, таким образом, онкология станет одной из главных причин смерти человека [1]. Согласно проведенным исследованиям [2], процент неправильно поставленных диагнозов достигает 50 %. Среди очагов появления онкологических патологий первое место занимают легкие – 27 % [1].

Одним из распространенных методов диагностики новообразований в легких является компьютерная томография (КТ). Однако в большинстве случаев первично представленной информации недостаточно, для того чтобы с достоверной точностью дифференцировать патологию. Это обусловлено сложной внутренней структурой легочных образований. Это в

конечном счете может привести к неточности выбранной стратегии лечения и ограничениям предоперационного планирования. Таким образом, крайне важна необходимость создания модели обработки и анализа КТ-изображений на основе внутренней структуры патологии.

Для доказательства выдвинутой нами гипотезы был проведен литературно-аналитический обзор, задачей которого являлось изучение существующих моделей обработки и анализа изображений с целью дифференцирования легочных патологий. В связи с тем, что на изображении представлена лишь плотность тканей, необходима предварительная обработка, которая позволит выделить дополнительные качественные признаки структуры тканей, а также анализ изображения и выделенных признаков, способствующий увеличению точности дифференцирования легочных патологий. В связи с этим разрабатываемая модель должна содер-

жать в себе две составляющие: обработку и анализ изображения.

Обработка изображения осуществляется путем выделения сегментов легочных патологий и извлечения качественных признаков, которые позволят в дальнейшем провести анализ изображения.

Анализ изображения в общем случае – применение методов классификации качественных признаков, полученных на этапе обработки изображения.

В настоящее время для осуществления обработки и анализа изображения существует множество алгоритмов и методов. Для выбора наиболее подходящего алгоритма следует учесть особенности проблемы, а именно:

- КТ-снимки – это набор растровых, полутоновых изображений, которые можно представить как трехмерную матрицу, значения элементов которой являются показаниями рентгеновской плотности ткани в данной точке;

- КТ-снимки имеют низкое разрешение;
- легочные патологии имеют характеристики, отличные от всех остальных патологий организма человека, такие как ровные и нечеткие края, наличие воздуха и др.

В процессе анализа литературы удалось выявить аналоги, которые способны частично решить вышеописанную проблему. Так, в [3] говорится о применении алгоритмов нечеткой связности и случайного леса для выделения и кластеризации патологии вместе с паренхимой для определения наличия патологии. В работе [4] говорится об успешном применении нейронных сетей для выделения и классификации патологий на изображениях флюорограмм. В [5] использован метод случайного поля Маркова-Гиббса для 3D-изображений легких, который является одним из самых точных методов.

Также существуют методы классификации патологий на изображениях: метод текстурного анализа и метод опорных векторов для поиска гриппа H1N1 на КТ-снимках легкого [6], а также метод адаптивных множественных особенностей для диагностирования и классификации хронической обструктивной болезни легких на ранних стадиях [7].

Результат проведенного литературно-аналитического обзора показал, что среди всех рассмотренных методов не удалось выявить модель, которая была бы применима к легочным патологиям и полностью решала бы поставленную проблему. Для разработки модели

нами были проанализированы аналоги методов обработки и анализа изображения, и в качестве прототипа нулевого ранга для модели был выбран аналог [4]. Для оценки были выбраны три критерия:

- 1) применимость модели для КТ-изображений;

- 2) применимость для анализа легочных патологий;

- 3) точность классифицирования патологий малого размера.

В качестве аналогов анализа изображения первого ранга нами были рассмотрены методы классификации. В качестве методов извлечения классификационных признаков рассматривались методы текстурного анализа. В процессе обработки изображения можно выделить два этапа: выделение области интереса (кластеризация или сегментация) и извлечение признаков.

Была произведена оценка рассмотренных методов, и для каждой группы был выбран ряд критериев, необходимых для реализации модели. Критерии оценки группы аналогов методов сегментации:

- время работы: критерий оценивает время работы алгоритма;

- степень автоматизации: оценивает необходимость вмешательства оператора в работу программы;

- конечность результата: критерий показывает, является ли результат сегментации конечным или используется как один из этапов.

Критерии оценки группы аналогов методов текстурного анализа:

- время работы алгоритма;

- необходимость реализации: критерий показывает, необходимо ли создание программы по существующей модели;

- количество текстурных признаков: критерий показывает достаточность текстурных признаков для проведения классификации;

- качество текстурных признаков: оценивает, насколько текстурные признаки позволяют произвести классификацию.

Критерии оценки группы аналогов методов классификации:

- время работы алгоритма;

- необходимость реализации;

- точность классификации: критерий оценивает процент правильно классифицированных патологий.

Один из способов классификации методов сегментации представлен в [8] и позволяет вы-

делить следующие классы методов сегментации: методы пороговой сегментации; методы поиска границ; метод, основанный на регионах; метод кластеризации; метод водоразделов; метод дифференциальных уравнений; метод нейронных сетей.

Методы пороговой сегментации являются простейшими методами сегментации изображений. Они позволяют сегментировать объект на фоне, таким образом выступая первым шагом сегментации. Преимуществом данного метода является его простота и отсутствие необходимости в предшествующей информации. Недостатком метода является неточность работы при наличии пиков на гистограмме яркости изображения.

Методы поиска границ основаны на кластеризации объектов. Он подходит для выделения объектов с четкими краями и не подходит для изображений, в которых края объектов нечеткие или их слишком много.

Методы сегментации на основе региона позволяют сегментировать изображение на различные области, имеющие аналогичные характеристики. Существует два основных метода, основанных на нем: это методы выращивания регионов и методы разделения и слияния регионов. Преимуществом данных методов является их устойчивость к шуму. Также они позволяют определять критерии подобия. Недостатком методов является их время работы и зависимость от памяти.

Метод кластеризации основан на выделении однородных кластеров. Преимуществом является наличие функции частичной принадлежности, благодаря этому он более подходит для решения реальных задач [1]. Недостатком является сложность определения функции принадлежности.

Метод водоразделов основан на топологической интерпретации изображения. Преимуществом метода является более стабильный результат, непрерывность обнаруженных границ. Недостаток метода – необходимость в комплексном расчете градиентов.

Метод дифференциальных уравнений основан на работе вычисления дифференциальных уравнений в частных производных. Лучше всего подходит для критически важных приложений. Недостаток метода – большая вычислительная сложность.

Метод на основе нейронных сетей основан на моделировании процесса обучения принятия

решений. Преимуществом метода является отсутствие необходимости в написании сложных программ. Недостаток – большая потеря времени, связанная с обучением сети.

Подходы к анализу текстуры очень разнообразны и отличаются друг от друга главным образом методом, используемым для извлечения текстурных признаков. Можно определить четыре категории.

1. Методы статистического анализа текстур в основном описывают текстуру областей в изображении через моменты высших порядков на гистограмме градаций серого [9]. Недостатком метода является высокая вычислительная сложность и большое разнообразие статистических характеристик, что делает необходимым изучение наиболее информативных признаков в зависимости от типа текстуры.

2. Методы структурного анализа текстур описывают текстуру как состав четко определенных текстурных элементов, таких как регулярные интервальные параллельные линии. Свойства и правила размещения элементов текстуры определяют текстуру изображения. Однако эти методы кажутся ограниченными по практичности, поскольку они могут описывать только очень регулярные текстуры [10].

3. Моделирующие методы анализа текстур создают эмпирическую модель каждого пикселя изображения, основанную на средневзвешенном значении интенсивности пикселей в его окрестности. Оценочные параметры моделей изображений используются в качестве текстовых описателей признаков. Примерами таких дескрипторов текстурной модели являются авторегрессионные модели [11], марковские случайные поля (*MRF*) [12] и фрактальные модели [13].

4. Основанные на преобразовании методы анализа текстур преобразуют изображение в новую форму с использованием пространственно-частотных характеристик изменений интенсивности пикселей, а также позволяют произвести сегментацию изображения [14].

Существуют следующие классы методов классификации [15].

1. Наивный классификатор Байеса – метод классификации, основанный на теореме Байеса и предполагающий, что наличие определенной функции в классе не связано с наличием какой-либо другой функции. Преимущество метода – простота построения классификатора, эффективность при работе с большим объемом



Рис. 1. Алгоритмическая модель предлагаемого решения

данных.

2. Логистическая регрессия – статистический метод для анализа набора данных, в котором есть одна или несколько независимых переменных, определяющих результат. Логистическая регрессия обладает преимуществами наивного классификатора и позволяет вероятностно оценить принадлежность к определенному классу.

3. Метод ближайших соседей является одним из простейших методов классификации, но, несмотря на это, применение позволяет получить хороший результат.

4. Дерево принятия решений строит модели классификации или регрессии в виде древовидной структуры. Метод также позволяет дать вероятностную оценку результату проведенной классификации.

5. Метод опорных векторов позволяет

классифицировать линейно неразделимые классы объектов. Применение метода позволило достичь 99,007 % точности классификации патологий в [6].

6. Случайные леса или леса с произвольным решением являются методом классификации, регрессии и других задач, которые работают путем построения множества деревьев принятия решений во время обучения и вывода класса.

7. Нейронная сеть является универсальным средством аппроксимации функций, что позволяет их использовать в решении задач классификации. Применение нейронных сетей в задачах классификации позволяет добиться точности до 99 %.

При оценке трех групп аналогов был выявлен компилятивный прототип, включающий в себя методы пороговой сегментации и струк-

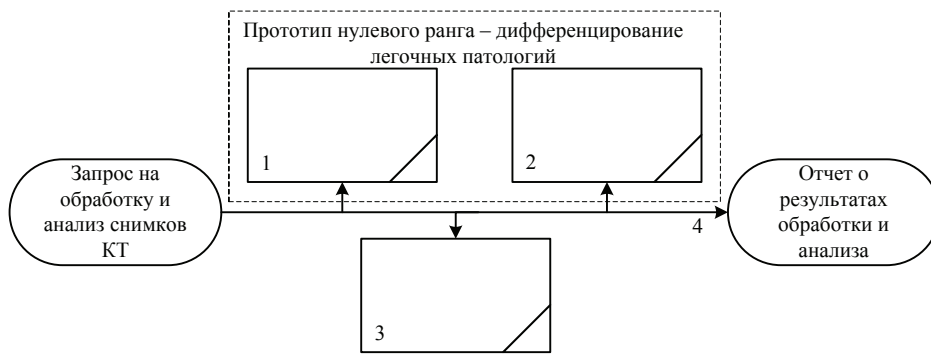


Рис. 2. Структурная модель предлагаемого решения

турные методы извлечения текстурных признаков, которые будут применены на этапе обработки изображения, и метод опорных векторов, применяемый на этапе анализа изображения.

Таким образом, предлагаемое решение заключается в разработке модели структурного анализа легочных патологий на основе текстурного анализа легочных патологий на снимках КТ с целью повышения точности дифференцирования легочных патологий.

На рис. 1 представлена алгоритмическая модель предлагаемого решения для определения структуры легочных патологий.

Также нами был разработан пакет математических моделей, каждая из которых описывает блоки, представленные на рис. 2. На рис. 2 использованы следующие обозначения.

1. Блок выделения классификационных признаков изображения. Новая подфункция – подфункция извлечения текстурных признаков блоков патологии. Вычисляет 5 признаков текстурного блок изображения: дисперсию, относительную гладкость, энтропию, момент третьего порядка и среднюю интенсивность.

2. Блок классификации патологии. Новая подфункция – подфункция подготовки признаков. Осуществляется в два этапа: обучение классификатора и основной этап. Обучение классификатора состоит в выполнении всего алгоритма на заранее классифицированных патологиях. Основной этап состоит в классификации патологий на основе полученных ранее данных. В результате работы модель возвращает класс патологии и точность классифицирования.

3. Блок сегментирования внутренней структуры патологии. Данная подсистема выполняет кластеризацию текстурных блоков ме-

тодом пороговой сегментации на основе полученных текстурных признаков.

4. Общий интерфейс.

Математическое моделирование

Входными данными решаемой задачи является набор снимков КТ, на котором представлена патология без прилегающих тканей. Окружающее пространство представлено пикселями со значениями -2048 . В памяти изображения представлены трехмерной матрицей A размера $M \times N \times K$, значениями элементов являются пиксели $z_{m,n,k}$, которые соответствуют плотности ткани по шкале Хаунсфилда; $p(z_i) - i = 0, 1, 2, \dots, L - 1$, – ее гистограмма; L – число значений плотностей:

$$A = \begin{pmatrix} 11 & \dots & 1_m \\ \vdots & \ddots & \vdots \\ n_1 & \dots & n_m \end{pmatrix}_k$$

Выделение классификационных признаков

Поскольку размер патологии может составлять от 20 до 60 пикселей, необходимо определить размер текстурного блока s , который будет содержать достаточное количество информации о текстуре, и в то же время количество текстурных блоков будет достаточно для проведения этапов сегментации и классификации. Оптимальный размер текстурного блока составляет 10 % от размера патологии, что обеспечивает $\sim 100-1000$ текстурных блоков. Если блок находится на границе патологии, то пиксели, находящиеся снаружи границ, не учитываются. Текстурный блок определяется по формуле:

$$B^{m^* n^* k^*} = \begin{pmatrix} n^* m^* & \dots & 2m^* \\ \vdots & \ddots & \vdots \\ 2n^* 1 & \dots & 2n^* 2m^* \end{pmatrix}_{k^*},$$

где $n^* = \{0, s, 2s, \dots, s(N/S + 1)\}$; $m^* = \{0, s, 2s, \dots, s(M/S + 1)\}$; $k^* = \{0, s, 2s, \dots, s^*(K/S + 1)\}$.

Для каждого рассчитывается $k = 5$ текстурных признаков по формулам, описанным в [10]:

- средняя яркость текстурного блока:

$$m = \sum_{i=0}^{L-1} z_i p(z_i);$$

- относительная гладкость текстурного блока (дисперсия):

$$R = 1 - \frac{1}{1 + \sigma^2(z)},$$

где $\sigma^2(z) = \sum_{i=0}^{L-1} (z_i - m)^2 p(z_i)$

- асимметрия текстурного блока:

$$\mu_3 = \sum_{i=0}^{L-1} (z_i - m)^3 p(z_i);$$

- однородность:

$$U = \sum_{i=0}^{L-1} p^2(z_i);$$

- энтропия:

$$e = - \sum_{i=0}^{L-1} p(z_i) \log_2 p(z_i).$$

Кластеризация внутренней структуры патологии

Для кластеризации внутренней структуры патологии будет использован выбранный метод пороговой сегментации. Данный метод группирует пиксели, чьи значения находятся в заданном интервале. Значения пикселей рассчитываются по формуле:

$$z'_i = - \sum_{k=1}^5 \frac{P_{i,k}}{\max p_k},$$

где k – текстурный признак.

Далее выполняется процедура пороговой

сегментации по формуле:

$$z'' = \begin{cases} 1, & \text{если } z'_i \geq T, \\ 0, & \text{если } z'_i < T, \end{cases}$$

где $T = \max_{t \in \{0, \dots, 255\}} SC(t)$.

В свою очередь, $SC(t)$ является критерием разделимости и вычисляется по формуле:

$$SC(t) = 1 - \frac{\sigma(\min(z), t) + \sigma(t + 1, \max(z))}{\sigma(\min(z), \max(z))},$$

$$t : [\min(z), \max(z)].$$

Классификация патологии

Процедура классификации осуществляется методом опорных векторов. Описание метода дано в [7]. Для обучения классификатора на вход необходимо подать массив векторов признаков вида:

$$v_b = \{c, z'', M, R, U, e, \mu_3\},$$

где $b = count(B)$, а $c = \{\text{рак туберкулома}\}$.

Для непосредственной классификации на вход классификатора подается вектор признаков неклассифицированной патологии:

$$v'_b = \{z'', M, R, U, e, \mu_3\}.$$

Таким образом, разработана модель структурного анализа КТ-изображения легочных патологий на основе предлагаемых критериев оценки структуры тканей, являющаяся комплексным методом обработки и анализа КТ-изображения с целью увеличения точности дифференцирования легочных патологий.

В ходе работы были получены как научные, так и практические результаты:

- рассмотрены особенности задачи структурного анализа патологий легких на КТ-изображении;
- сформулированы и проанализированы проблемы, обоснованные структурной сложностью патологий легких;
- проведен литературно-аналитический обзор существующих способов решения поставленных задач;
- предложена концепция модели определения структуры патологий легких на основе КТ-изображений, включающая современные

методы сегментации и фрактального анализа изображений, позволяющие учитывать структурные особенности текстуры изображений легочных патологий;

– разработан пакет различных моделей, в том числе, математических, позволяющих проиллюстрировать новизну предлагаемого решения.

Работа выполнена в рамках проекта НИЦ «Авантред» – «Программный модуль дифференцирования легочных патологий».

Литература

1. Чучалин, Г.А. Пульмонология : нац. рук. / Г.А. Чучалин. – М. : ГЭОТАР-Медиа, 2009. – 957 с.
2. Bostrom, P.J. Staging and Staging Errors in Bladder Cancer / P.J. Bostrom, B.W.G. van Rhijn and et. // Science Direct. – 2010. – № 9. – С. 2–9.
3. Mansoor, A. A Generic Approach to Pathological Lung Segmentation / A. Mansoor, U. Bagci, Ziyue Xu, B. Foster, N. Kenneth and et. // IEEE Trans Med Imaging. – 2014. – P. 2293–2310.
4. Дюдин, М.В. Методы, модели и алгоритмы анализа и классификации растровых изображений рентгенограмм грудной клетки : дисс. ... канд. техн. наук / М.В. Дюдин. – Курск, 2016. – 154 с.
5. Soliman, A. Accurate Lungs Segmentation on CT Chest Images by Adaptive Appearance-Guided Shape Modeling / A. Soliman, F. Khalifa, A. Elnakib and et. // IEEE Transactions on Medical Imaging. – 2017. – Vol. 36. – No. 1. – P. 263–276.
6. Yao, J. Computer-aided diagnosis of pulmonary infections using texture analysis and support vector machine classification / J. Yao, A. Dwyer, R.M. Summers, D.J. Mollura // Acad Radiol. – 2011. – Vol. 18. – No. 3. – P. 306–314.
7. Xu Ye. Sensitivity and Specificity of 3D texture analysis of lung parenchyma is better than 2D for discrimination of lung pathology in Stage 0 COPD / Xu Ye, Sonka Milan, Mclennan Geoffrey, Guo Junfeng, Hoffman Eric // Proc SPIE. – 2005. – No. 5746. – P. 474–485.
8. Kaur, D. Various Image Segmentation Techniques: A Review / D. Kaur, Y. Kaur // International Journal of Computer Science and Mobile Computing. – 2014. – Vol. 3. – Iss. 5. – P. 809–814.
9. Kemal Akyo. Automatic Detection of Optic Disc in Retinal Image by Using Keypoint Detection, Texture Analysis, and Visual Dictionary Techniques / Kemal Akyo, Baha Fen, Fafak Bay Jr. // Computational and Mathematical Methods in Medicine, 2016 [Electronic resource]. – Access mode : <https://doi.org/10.1155/2016/6814791>.
10. Gonzalez, R.C. Digital Image Processing / R.C. Gonzalez, R.E. Woods // Addison-Wesley, Reading, 1992. – P. 797.
11. Васильев, К.К. Авторегрессионные модели многомерных изображений / К.К. Васильев, В.Е. Дементьев // Научные технологии. – М. – 2013. – Т. 14. – № 5. – С. 12–15.
12. Медведева, Е.В. Метод текстурной сегментации изображений на основе марковских случайных полей / Е.В. Медведева, Е.Е. Курбатова // Цифровая Обработка Сигналов. – 2012. – № 3. – С. 76–80.
13. Привезенцев, Д.Г. Фрактальная модель цифрового изображения / Д.Г. Привезенцев, А.Л. Жизняков // Алгоритмы, методы и системы обработки данных. – Муром. – 2010. – № 15. – С. 147–152.
14. Heiberg, E. Design and validation of Segment – freely available software for cardiovascular image analysis / E. Heiberg, J. Sjogren, M. Ugander, M. Carlsson, H. Engblom, H. Arheden // BMC Med Imaging. – 2010. – Vol. 10.
15. Types of classification algorithms in Machine Learning [Electronic resource]. – Access mode : <https://medium.com/@sifium/machine-learning-types-of-classification-9497bd4f2e14>.

References

1. Chuchalin, G.A. Pulmonologiya : nats. ruk. / G.A. Chuchalin. – M. : GEOTAR-Media,

2009. – 957 s.

4. Dyudin, M.V. Metody, modeli i algoritmy analiza i klassifikatsii rastrovnykh izobrazheniy rentgenogramm grudnoy kletki : diss. ... kand. tekhn. nauk / M.V. Dyudin. – Kursk, 2016. – 154 s.

11. Vasilev, K.K. Avtoregressionnyye modeli mnogomernykh izobrazheniy / K.K. Vasilev, V.E. Dementev // Naukoemkie tekhnologii. – M. – 2013. – T. 14. – № 5. – S. 12–15.

12. Medvedeva, E.V. Metod teksturnoy segmentatsii izobrazheniy na osnove markovskikh sluchaynykh poley / E.V. Medvedeva, E.E. Kurbatova // TSifrovaya Obrabotka Signalov. – 2012. – № 3. – S. 76–80.

13. Privezentsev, D.G. Fraktalnaya model tsifrovogo izobrazheniya / D.G. Privezentsev, A.L. Zhiznyakov // Algoritmy, metody i sistemy obrabotki dannykh. – Murom. – 2010. – № 15. – S. 147–152.

© С.Н. Соловьева, Д.А. Рычков, 2020