

**Zhukov Yuriy Aleksandrovich** – Baltic State Technical University «VOENMEH»; e-mail: zhkv@rambler.ru; 1, 1st Krasnoarmeyskaya street, Saint-Petersburg, 190005, Russia; phone: +79112354201; senior lecturer; scientific employee, research laboratory of robotic and mechatronic systems.

**Korotkov Evgeniy Borisovich** – e-mail: ebkorotkov@yandex.ru; phone: +79219381511; cand. of eng. sc.; associate professor; chief scientific employee, research laboratory of robotic and mechatronic systems.

**Moroz Aleksandr Viktorovich** – e-mail: avmor1@mail.ru; phone: +79062664477; senior lecturer; scientific employee, research laboratory of robotic and mechatronic systems.

УДК 004.94

DOI 10.23683/2311-3103-2018-8-241-249

**Л.В. Уткин, А.А. Мелдо, О.С. Ипатов, М.А. Рябинин**

**МЕДИЦИНСКИЕ ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ НА ПРИМЕРЕ  
ДИАГНОСТИКИ РАКА ЛЕГКОГО\***

*Учитывая стремительное развитие новых методов искусственного интеллекта и большое количество новых разработок, связанных с созданием интеллектуальных систем диагностики онкологических заболеваний, целью работы является рассмотрение особенностей таких систем и разработка перспективной архитектуры системы, повышающей эффективность их обучения и достоверность получаемых результатов диагностики. В работе предлагается краткий анализ интеллектуальных систем диагностики онкологических заболеваний на примере обнаружения рака легкого по снимкам компьютерной томографии, которая в настоящее время является основным диагностическим инструментом для определения распространенности рака лёгкого, поиска регионарных и отдаленных метастазов. Рассмотрены основные виды существующих интеллектуальных систем диагностики и дана их классификация с точки зрения использования методов обработки информации компьютерной томографии. Дано описание типовой последовательности этапов обработки изображений компьютерной томографии для обнаружения злокачественных образований в легком, которая включает такие процедуры, как сбор данных, предварительную обработку изображения, сегментацию, обнаружение образований, сокращение числа ложноположительных случаев и классификацию новообразований. Показано, что основной проблемой большинства систем дифференциальной диагностики является тот факт, что обучающая выборка содержит мало альтернативных примеров и не может быть в полной мере использована для обучения интеллектуальной системы. Для решения этой проблемы в работе предлагается новая архитектура интеллектуальной системы диагностики, позволяющая на последних этапах обработки данных существенно повысить точность классификации образований в легком. Основой этой архитектуры является симметричная нейронная сеть, которая состоит из двух одинаковых подсетей, объединенных на выходе. Процесс обучения сети использует все возможные пары образцов из базы изображений злокачественных образований, что существенно увеличивает размер обучающей выборки и позволяет устранить эффект переобучения. В процессе эксплуатации для анализа неизвестного образования на вход одной из сетей подается исследуемое изображение компьютерной томографии образца неизвестного образования, а на вход второй сети – изображение из базы злокачественных образований.*

*Искусственный интеллект; система диагностики; рак легкого; компьютерная томография; нейронная сеть; обработка изображений.*

---

\* Исследование выполнено за счет гранта Российского научного фонда (проект № 18-11-00078).

L.V. Utkin, A.A. Meldo, O.S. Ipatov, M.A. Ryabinin

## MEDICAL ARTIFICIAL INTELLIGENCE SYSTEMS USING AN EXAMPLE OF THE LUNG CANCER DIAGNOSIS

*By taking into account a rapid development of new methods of artificial intelligence and a large number of new developments related to intelligent systems for diagnosing oncological diseases, the aim of the work is to consider the main peculiarities of such the systems and develop a perspective system architecture that allows us to increase the efficiency of their training process and the accuracy of the diagnostic results. The paper proposes a brief analysis of intelligent systems for diagnosing oncological diseases using an example of the lung cancer detection from computed tomography images, which are currently the main diagnostic tool for determining the prevalence of lung cancer, searching for local and distant metastases. The main types of existing intelligent diagnostic systems are considered and divided in subgroups from the point of view of the computed tomography information processing method usage. A description of the typical sequence of stages of the computed tomography image processing for detection of malignant tumors in the lung, which includes such procedures as the dataset collection, image pre-processing, segmentation, detection of lung nodules, reducing the number of false-positive cases and the classification of tumors. It is shown that the main problem of most differential diagnosis systems is a fact that the training sample contains few alternative examples of various types of cancer and cannot be fully used to train the intelligent diagnostics system. To solve this problem, a new architecture of the intelligent diagnostics system is proposed in the paper, which makes it possible to significantly increase the accuracy of the lung nodule classification at the last stages of data processing. The main basis of this architecture is the Siamese neural network, which consists of two identical subnets with shared parameters connected at the output. The neural network training process uses all possible pairs of samples from the image base of malignant tumors, which significantly increases the size of the training sample and eliminates the effect of overfitting. During testing the system, an analyzed computed tomography image as an example of an unknown tissue is fed to the input of one of the networks, and an image from the base of malignant tumors is fed to the input of the second network.*

*Artificial intelligence; diagnostic system; lung cancer; computed tomography; neural network; image processing.*

**Введение.** Ежегодно в мире регистрируется огромное число онкологических больных и, в частности, больных раком легкого. В настоящее время в условиях развития информационных технологий, совершенствования новых методов компьютерной томографии (КТ), ультразвукового исследования и других методов медицинского обследования пациентов, проблемы диагностики онкологических заболеваний становятся более значимыми. Стремительное развитие новых методов искусственного интеллекта, в частности, одной из его составляющих, машинного обучения, в сочетании со все большим использованием суперкомпьютеров, которые являются основой существенного повышения производительности средств вычислительной техники, привели к стремительному росту интереса к этой области со стороны ученых, врачей и исследователей. Результатом такого интереса явилось большое количество новых разработок, связанных с созданием интеллектуальных систем диагностики (ИСД) онкологических заболеваний, цель которых – выявление заболеваний на всех стадиях и определение оптимального вида лечения.

Если рассматривать ИСД рака легкого, то необходимо отметить, что большинство их реализаций используют трехмерные снимки КТ, которое является основным диагностическим инструментом для определения распространенности рака лёгкого, поиска регионарных и отдаленных метастазов [1]. Снимки обычно имеют формат DICOM (Digital Imaging and Communication in Medicine), который затем представляется в виде серии сканов как последовательность 2D-изображений, а интервал между этими 2D-изображениями называется Z-интервалом. Компьютерная томография сочетает в себе информативность представления данных о пациенте и меньшую

финансовую нагрузку по сравнению с магнитно-резонансной томографией или позитронно-эмиссионной томографией. В тоже время, обработка и анализ снимков КТ требуют значительных затрат времени врача, что делает актуальным создание интеллектуальных систем диагностики на основе КТ. Это привело к значительному числу публикаций, посвященных различным реализациям интеллектуальных систем диагностики, использующих снимки КТ [2-15].

Целью предлагаемой работы является краткий анализ процесса обнаружения злокачественных образований в легком и рассмотрение нового подхода, основанного на использовании глубоких свамских сетей для классификации образований с учетом параллельной реализации системы на суперкомпьютере. Особенность предлагаемой архитектуры заключается в ее универсальности. В качестве свамской сети можно брать как простейшие нейронные сети, так и сверточные сети, что определяется представлением входных данных.

**Основные этапы обработки снимков КТ и виды ИСД.** В большинстве ИСД процедура обнаружения новообразований в легком на основе изображений КТ состоит из следующих этапов [2-15]: сбор данных, предварительная обработка изображения, сегментация, обнаружение образований, сокращение числа ложноположительных случаев и классификация новообразований.

Этап сбора данных для обучения определяется способом получения медицинских изображений. В основном используются либо результаты проведенных КТ, которые получены в больницах или научных центрах, либо открытые базы данных, которые используются разработчиками ИСД. К последним можно отнести известные базы LIDC (Lung Image Database Consortium) и LUNA16 (LUng Nodule Analysis 2016 Challenge). Предварительная обработка изображений ставит своей целью обнаружение всех «подозрительных» образований путем фильтрации тканей легких для повышения точности последующих этапов обработки изображений. В соответствии с этой процедурой данные или значения пикселей в каждом изображении преобразуются в значения т.н. рентгеновской плотности по шкале Хаунсфилда (шкала поглощения рентгеновского излучения, HU), в которой за 0 принята плотность воды. Воздух обычно имеет значения около -1000 HU, средние значения денситометрической плотности лёгочной ткани -600 – -400. Интервал от -200 до 100 значений плотности используется для реализации процедуры сегментации. Используя разницу плотностного диапазона между лёгочной тканью, обладающей так называемой естественной контрастностью, и мягкими тканями, имеющими положительные значения по шкале Хаунсфилда от +40 до +80, метод сегментации представляется, несомненно, эффективным. Воксели, которые находятся за пределами этой области плотностного диапазона и соответствуют сосудам, воде, воздуху и т.д., «маскируются» для того, чтобы оставить для анализа только легочную ткань. Полученные 2D-фрагменты укладываются в одно трехмерное изображение.

Сегментацию легких можно рассматривать как процесс отделения новообразований от нормальной ткани и органов на изображениях КТ. На этом этапе осуществляется выделение вокселей, описывающих границы «кандидатов» новообразований. Эта процедура обычно выполняется при помощи стандартных процедур графической обработки изображения по цветам объектов на нем, а также с использованием глубокой сверточной сети, ориентированной на сегментацию изображений. В рамках использования процедур графической обработки изображения сегментация новообразований может быть реализована с помощью последовательного применения алгоритма покадровой заливки изображений, а также применением к найденным объектам в легком алгоритма дилатации, который учитывает плотность соседних с объектом точек, и, если плотность не входит в заданный диапазон, построение объекта в данном направлении заканчивается. К наиболее популярным

лярным нейронным сетям, используемым в большинстве реализаций интеллектуальных систем сегментации в медицинской диагностике, можно отнести нейронную сеть U-Net [16]. Сеть содержит сжимающий путь, включающий последовательность сверточных слоев и слоев пулинга, т.е. обычную сверточную сеть, а также расширяющий путь, который содержит слои, выполняющие операции, обратные пулингу, в целях расширения карты признаков, а также операции свертки для уменьшения количества каналов признаков. Архитектура похожа на букву U, что привело к соответствующему названию сети. Следует отметить, что другой эффективной глубокой нейронной сетью для сегментации является SegNet [17]. Таким образом, в результате сегментации получают предварительную визуализацию с выделенными границами «кандидатов» новообразований.

Целью этапа классификации новообразований в лёгком является определение их принадлежности к злокачественным или доброкачественным образованиям. Различные методы классификации новообразований можно найти в литературе [6, 13], включая методы, использующие морфологические признаки. На этом этапе остается много ложноположительных случаев, которые характеризуются неправильно идентифицированными образованиями. Целью этапа сокращения числа ложноположительных случаев является исключение ложных новообразований, которые неправильно идентифицированы на предыдущих этапах. Для сокращения числа ложноположительных случаев на основе выделенных признаков используются различные виды классификаторов, например, полносвязанные нейронные сети, глубокие нейронные сети, случайные леса и т.д. Выбор того или иного классификатора зависит от конкретной реализации всей ИСД.

Приведенный выше перечень шагов может быть расширен и изменен в зависимости от рассматриваемой ИСД. Более того, ряд ИСД использует только некоторые из перечисленных этапов. Наиболее важным и сложным с точки зрения реализации являются два последних, а именно, сокращение числа ложноположительных случаев и классификация новообразований.

Анализ литературы, описывающей различные виды ИСД рака легкого, показал, что большинство систем диагностирования можно разделить на три основных класса с точки зрения использования методов обработки информации КТ:

1. Системы, использующие стандартную обработку изображений и принятие решений на основе методов обработки изображений. Фактически, такие системы нельзя назвать интеллектуальными, так как они не основаны на процессе обучения, а используют обычные алгоритмы. Главным недостатком этих систем также является относительно большое количество ложноположительных результатов, когда различные элементы легких распознаются как злокачественные новообразования, в то время как они таковыми не являются. Кроме того, соответствующие методы требуют существенных вычислительных ресурсов в процессе их использования, т.е. в процессе обнаружения опухоли. В настоящее время наблюдается тенденция замены этих методов на методы искусственного интеллекта.

2. Системы, использующие методы «неглубокого» обучения. Второй класс систем использует такие методы машинного обучения, как случайные леса, метод опорных векторов, простейшие нейронные сети и т.п. Этот класс ИСД обычно использует в качестве входных данных геометрические и плотностные параметры предварительно сегментированных новообразований.

3. Системы, использующие методы глубокого обучения. Третий класс ИСД основан на использовании методов глубокого обучения, включая различные виды сверточных нейронных сетей для сегментации и классификации новообразований. ИСД этого класса в большинстве случаев обрабатывают снимки КТ как изображения в целом.

На самом деле это разделение условно и во многих ИСД реализуются все методы на разных этапах обработки. В частности алгоритмы первого класса используются в большинстве систем на этапе предварительной обработки изображений КТ, например, при реализации методов фильтрации и других подходов к обработке изображений.

**Сиамская нейронная сеть для классификации злокачественных образований.** Несмотря на большое разнообразие ИСД для обнаружения рака легкого, большинство систем недостаточно эффективно распознают злокачественные и доброкачественные образования или какие-либо другие ткани. Прежде всего, это связано с вариабельностью представления рака легкого на снимках КТ, которая, в свою очередь, связана с морфологическим субстратом (аденокарцинома, плоскоклеточный рак и т.д.), а также с типом роста опухоли (узловой, стелящийся, перибронхиальный). Кроме того, каждый день в медицинских учреждениях обнаруживают совершенно новые виды злокачественных образований с точки зрения их формы, плотности и других характеристик. Описанные в литературе системы диагностики рака легкого учитывают в основном узловые новообразования с типичной картиной на снимках КТ и схожей структурой.

Основное препятствие для обучения ИСД при анализе этих новых и особенных случаев опухолей заключается в том, что обучающая выборка содержит мало альтернативных примеров. Это делает использование системы проблематичным в реальной медицинской практике. Такая ситуация схожа с машинным обучением по единичным примерам (one-shot learning), одним из алгоритмов которого является применение сиамских нейронных сетей [18]. Поэтому мы предлагаем новую архитектуру ИСД, позволяющую на последних этапах обработки данных существенно повысить точность классификации образований в легком. Основой этой архитектуры является сиамская нейронная сеть [19]. Архитектура сиамских сетей уже была использована в ряде прикладных задач, задачах глубокого обучения, например, для проверки соответствия изображений лиц [20], в обучении, в котором прогнозирование выполняется при наличии только одного примера в каждом классе данных [18].

Сиамская сеть состоит из двух одинаковых подсетей, объединенных на выходе [19]. Две подсети преобразуют признаки образцов образований из базы данных, одновременно поданных на входы подсетей в процессе обучения, а их объединенный выход определяет расстояние между двумя векторами преобразованных признаков. При этом указываются являются ли оба образца злокачественными или нет. Таким образом, процесс обучения сети использует все возможные пары образцов, которые имеются в распоряжении, что существенно увеличивает размер обучающей выборки и позволяет устранить эффект переобучения.

В процессе эксплуатации пары входных данных для сиамской сети образуются следующим образом. На первый вход подается исследуемый образец неизвестного образования, а на второй – образец из базы злокачественных образований (БЗО). Если нейронная сеть показала близость этих объектов, то принимается решение, что исследуемый образец является злокачественным. В противном случае на второй вход подается следующий образец из БЗО, и процедура повторяется. Если при сопоставлении исследуемого образца со всеми образцами из базы во всех случаях сиамская сеть показала отсутствие близости объектов, то принимается решение, что исследуемый образец не является злокачественным.

На рис. 1 схематично показан процесс обучения сиамской нейронной сети, когда на два входа подаются сегментированные изображения новообразований в виде векторов (или матриц)  $x_1$  и  $x_2$ , полученные из снимков КТ легких (две фотографии слева). Здесь  $E_1$  и  $E_2$  – две подсети с одинаковыми весами соединений. Вы-

ходы подсетей – новое представление признаков  $\mathbf{h}_i$  и  $\mathbf{h}_j$ . Нейронная сеть обучается таким образом, чтобы евклидово расстояние между векторами  $\mathbf{h}_i$  и  $\mathbf{h}_j$  было малым, если оба образования на входе злокачественные или оба – доброкачественные. Если одно из них является злокачественным, а второе – доброкачественным, то расстояние между  $\mathbf{h}_i$  и  $\mathbf{h}_j$  делается большим. При этом все примеры берутся из БЗО. В качестве  $E_1$  и  $E_2$  используются сверточные нейронные сети.




Рис. 1. Обучение сиамской нейронной сети

Использование обученной сиамской сети аналогично. Пусть  $\mathbf{x}$  – новый образец (снимок КТ нового пациента), а  $\mathbf{x}_i$  – образец из БЗО. Структура процесса использования сиамской сети показана на рис. 2. Выходы подсетей – новое представление признаков  $\mathbf{h}$  и  $\mathbf{h}_i$ . Евклидово расстояние между выходами, обозначенное  $d(\mathbf{h}, \mathbf{h}_i)$ , определяет насколько новый образец можно считать злокачественным или нет. При этом новый образец сравнивается таким образом со всеми снимками КТ, хранящимися в БЗО. Снимок из БЗО с минимальным евклидовым расстоянием  $d(\mathbf{h}, \mathbf{h}_i)$  соответствует диагнозу пациента.




Рис. 2. Структура сиамской сети и база злокачественных образований

Особенность предлагаемой архитектуры заключается в ее универсальности. В качестве сиамской сети можно брать как простейшие нейронные сети, так и сверточные сети, что определяется представлением входных данных. Кроме того, БЗО может постоянно пополняться без дополнительного обучения сети, что позволит повышать точность классификации. При наличии нескольких представлений входных данных можно реализовать множество сиамских сетей или каскад сетей, что позволит принимать решение на основе композиции классификаторов.

В то же время, необходимо отметить один существенный недостаток архитектуры. Он заключается в том, что для принятия решений необходимо перебрать все образцы из БЗО. Это может привести с существенным потерям времени. Одна-

ко такая обработка достаточно эффективно может быть реализована в рамках параллельных вычислений с использованием суперкомпьютера. Снимок нового пациента параллельно сравнивается со всеми снимками из БЗО, что не требует дополнительного решения задачи распараллеливания. Поэтому именно такая реализация наилучшим образом ориентирована на применение суперкомпьютеров.

**Заключение.** В представленной работе предложена новая архитектура ИСД, позволяющая значительно повысить эффективность обнаружения рака легкого. В то же время, несмотря на ее ориентацию на заболевания легкого, архитектура является универсальной и может быть достаточно просто применена и для других онкологических заболеваний. Кроме того, формат представления данных для ее обучения и использования существенно зависит от этапа обработки информации, на котором она используется. Предлагаемая реализация ориентирована на этапы исключения ложных новообразований и классификации. Однако, создавая каскадную структуру сиамских нейронных сетей, можно ее использовать и на более ранних этапах обработки снимков КТ.

#### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Ганцев, Ш.Х., Моисеенко В.М., Арсеньев А.И., Чижиков А.В., Моисеенко Ф.В., Мелдо А.А. Рак лёгкого. – М.: ГЭОТАР-Медиа, 2017. – 224 с.
2. Мелдо А.А., Уткин Л.В. Обзор методов машинного обучения в диагностике рака легкого // Искусственный интеллект и принятие решений. – 2018. – № 3. – С. 28-38.
3. Choi W.J., Choi T.S. Automated pulmonary nodule detection based on three-dimensional shape-based feature descriptor // Computer Methods and Programs in Biomedicine. – 2014. – Vol. 113. – P. 37-54.
4. Chon A., Balachandar N., Lu P. Deep convolutional neural networks for lung cancer detection // Technical report, Stanford University, 2017.
5. Froz B.R., de C. Filhoa A.O., Silva A.C., de Paiva A.C., Nunes R.A., Gattass M. Lung nodule classification using artificial crawlers, directional texture and support vector machine // Expert Systems With Applications. – 2017. – Vol. 69. – P. 176-188.
6. Firmino M., Morais A.H., Mendoca R.M., Dantas M.R., Hekis H.R., Valentim R. Computer-aided detection system for lung cancer in computed tomography scans: review and future prospects // Biomedical engineering online. – 2014. – Vol. 13 (1). – P. 41.
7. Huang X., Shan J., Vaidya V. Lung nodule detection in CT using 3D convolutional neural networks // 14th International Symposium on Biomedical Imaging (ISBI 2017). IEEE, April 2017. – P. 379-383.
8. John J., Mini M.G. Multilevel thresholding based segmentation and feature extraction for pulmonary nodule detection // Procedia Technology. – 2016. – Vol. 24. – P. 957-963.
9. Kuruvilla J., Gunavathi K. Lung cancer classification using neural networks for CT images // Computer Methods and Programs in Biomedicine. – 2014. – Vol. 113. – P. 202-209.
10. Liu X., Hou F., Qin H., Hao A. Multi-view multi-scale CNNs for lung nodule type classification from CT images // Pattern Recognition. – 2018. – Vol. 77. – P. 262-275.
11. Nithila E.E., Kumar S.S. Automatic detection of solitary pulmonary nodules using swarm intelligence optimized neural networks on CT images // Engineering Science and Technology, an International Journal. – 2017. – Vol. 20 (3). – P. 1192-1202.
12. Park S.C., Tan J., Wang X., Lederman D., Leader J.K., Kim S.H., and Zheng B. Computer-aided detection of early interstitial lung diseases using low-dose CT images // Physics in Medicine and Biology. – 2011. – Vol. 56. – P. 1139-1153.
13. Rehman M.Z., Javaid M., Shah S.I.A., Gilani S.O., Jamil M., Butt S.I. An appraisal of nodules detection techniques for lung cancer in CT images // Biomedical Signal Processing and Control. – 2018. – Vol. 41. – P. 140-151.
14. Yuan J., Liu X., Hou F., Qin H., Hao A. Hybrid-feature-guided lung nodule type classification on CT images // Computers & Graphics. – 2018. – Vol. 70. – P. 288-299.
15. Zhu W., Liu C., Fan W., and Xie X. DeepLung: Deep 3D dual path nets for automated pulmonary nodule detection and classification // arXiv: 1801.09555v1, Jan 2018.

16. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // International Conference on Medical image computing and computer-assisted intervention. – Springer, Cham, 2015. – P. 234-241.
17. Badrinarayanan V., Kendall A., Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2017. – Vol. 39, No. 12. – P. 2481-2495.
18. Koch G., Zemel R., Salakhutdinov R. Siamese neural networks for one-shot image recognition // Proceedings of the 32nd International Conference on Machine Learning. Lille, France, 2015. – Vol. 37. – P. 1-8.
19. Bromley J., Bentz J.W., Bottou L., Guyon I., LeCun Y., Moore C., Sackinger E., Shah R. Signature verification using a Siamese time delay neural network // International Journal of Pattern Recognition and Artificial Intelligence. – 1993. – Vol. 7 (4). – P. 737-744.
20. Chopra S., Hadsell R., LeCun Y. Learning a similarity metric discriminatively, with application to face verification // 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). IEEE, 2005. – Vol. 1. – P. 539-546.

## REFERENCES

1. Gantsev, Sh.Kh., Moiseenko V.M., Arsen'ev A.I., Chizhikov A.V., Moiseenko F.V., Meldo A.A. Rak legkogo [Lung cancer]. Moscow: GEOTAR-Media, 2017, 224 p.
2. Meldo A.A., Utkin L.V. Obzor metodov mashinnogo obucheniya v diagnostike raka legkogo [Review of machine learning methods in lung cancer diagnosis], *Iskusstvennyy intellekt i prinyatie resheniy* [Artificial intelligence and decision making], 2018, No. 3, pp. 28-38.
3. Choi W.J., Choi T.S. Automated pulmonary nodule detection based on three-dimensional shape-based feature descriptor, *Computer Methods and Programs in Biomedicine*, 2014, Vol. 113, pp. 37-54.
4. Chon A., Balachandar N., Lu P. Deep convolutional neural networks for lung cancer detection, *Technical report, Stanford University*, 2017.
5. Froz B.R., de C. Filhoa A.O., Silva A.C., de Paiva A.C., Nunes R.A., Gattass M. Lung nodule classification using artificial crawlers, directional texture and support vector machine, *Expert Systems With Applications*, 2017, Vol. 69, pp. 176-188.
6. Firmino M., Morais A.H., Mendoca R.M., Dantas M.R., Hekis H.R., Valentim R. Computer-aided detection system for lung cancer in computed tomography scans: review and future prospects, *Biomedical engineering online*, 2014, Vol. 13 (1), pp. 41.
7. Huang X., Shan J., Vaidya V. Lung nodule detection in CT using 3D convolutional neural networks, *14th International Symposium on Biomedical Imaging (ISBI 2017)*. IEEE, April 2017, pp. 379-383.
8. John J., Mini M.G. Multilevel thresholding based segmentation and feature extraction for pulmonary nodule detection, *Procedia Technology*, 2016, Vol. 24, pp. 957-963.
9. Kuruvilla J., Gunavathi K. Lung cancer classification using neural networks for CT images, *Computer Methods and Programs in Biomedicine*, 2014, Vol. 113, pp. 202-209.
10. Liu X., Hou F., Qin H., Hao A. Multi-view multi-scale CNNs for lung nodule type classification from CT images, *Pattern Recognition*, 2018, Vol. 77, pp. 262-275.
11. Nithila E.E., Kumar S.S. Automatic detection of solitary pulmonary nodules using swarm intelligence optimized neural networks on CT images, *Engineering Science and Technology, an International Journal*, 2017, Vol. 20 (3), pp. 1192-1202.
12. Park S.C., Tan J., Wang X., Lederman D., Leader J.K., Kim S.H., and Zheng B. Computer-aided detection of early interstitial lung diseases using low-dose CT images, *Physics in Medicine and Biology*, 2011, Vol. 56, pp. 1139-1153.
13. Rehman M.Z., Javaid M., Shah S.I.A., Gilani S.O., Jamil M., Butt S.I. An appraisal of nodules detection techniques for lung cancer in CT images, *Biomedical Signal Processing and Control*, 2018, Vol. 41, pp. 140-151.
14. Yuan J., Liu X., Hou F., Qin H., Hao A. Hybrid-feature-guided lung nodule type classification on CT images, *Computers & Graphics*, 2018, Vol. 70, pp. 288-299.
15. Zhu W., Liu C., Fan W., and Xie X. DeepLung: Deep 3D dual path nets for automated pulmonary nodule detection and classification, *arXiv: 1801.09555v1, Jan 2018*.



16. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation, *International Conference on Medical image computing and computer-assisted intervention*. Springer, Cham, 2015, pp. 234-241.
17. Badrinarayanan V., Kendall A., Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, Vol. 39, No. 12, pp. 2481-2495.
18. Koch G., Zemel R., Salakhutdinov R. Siamese neural networks for one-shot image recognition, *Proceedings of the 32nd International Conference on Machine Learning. Lille, France, 2015*, Vol. 37, pp. 1-8.
19. Bromley J., Bentz J.W., Bottou L., Guyon I., LeCun Y., Moore C., Sackinger E., Shah R. Signature verification using a Siamese time delay neural network, *International Journal of Pattern Recognition and Artificial Intelligence*, 1993, Vol. 7 (4), pp. 737-744.
20. Chopra S., Hadsell R., LeCun Y. Learning a similarity metric discriminatively, with application to face verification, *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). IEEE, 2005*, Vol. 1, pp. 539-546.

Статью рекомендовал к опубликованию д.т.н., профессор В.С. Заборовский.

**Уткин Лев Владимирович** – Санкт-Петербургский политехнический университет Петра Великого; e-mail: lev.utkin@mail.ru; 195251, Санкт-Петербург, Политехническая ул., 29; д.т.н.; профессор; зав. лабораторией нейросетевых технологий и искусственного интеллекта; зав. кафедрой «Телематика (при ЦНИИ РТК)».

**Ипатов Олег Сергеевич** – e-mail: ipatov\_os @spbstu.ru; д.т.н.; профессор; начальник управления научных исследований и разработок.

**Рябинин Михаил Андреевич** – e-mail: mihail-gyabinin@yandex.ru; аспирант кафедры «Телематика (при ЦНИИ РТК)»; инженер лаборатории нейросетевых технологий и искусственного интеллекта.

**Мелдо Анна Александровна** – ГБУЗ «Санкт-Петербургский клинический научно-практический центр специализированных видов медицинской помощи (онкологический)»; e-mail: anna.meldo@yandex.ru; 197758, Санкт-Петербург, п. Песочный, Ленинградская ул., 68А; к.мед.н.; зав. отделением лучевой диагностики; врач-рентгенолог; с.н.с. лаборатории нейросетевых технологий и искусственного интеллекта, Санкт-Петербургский политехнический университет Петра Великого.

**Utkin Lev Vladimirovich** – Peter the Great Saint-Petersburg Polytechnic University; e-mail: lev.utkin@mail.ru; 29, Polytechnicheskaya street, St.Petersburg, 195251, Russia; dr. of eng. sc.; professor; head of the telematics department and the Research Laboratory of Neural Network Technologies and Artificial Intelligence.

**Ipatov Oleg Sergeevich** – e-mail: ipatov\_os @spbstu.ru; dr. of eng. sc.; professor; head of research and development department.

**Ryabinin Mikhail Andreevich** – e-mail: ryabinin@yandex.ru; doctorate student of the telematics department and engineer of the Research Laboratory of Neural Network Technologies and Artificial Intelligence.

**Meldo Anna Alexandrovna** – Saint-Petersburg Clinical Research Center of Specialized Types of Medical Care (Oncological); e-mail: anna.meldo@yandex.ru; 68A, Leningradsky street, Pesochny, St. Petersburg, 197758, Russia; cand. of med. sc.; head of the radiology department; radiologist; of senior scientist of the research Laboratory of Neural Network Technologies and Artificial Intelligence, Peter the Great Saint-Petersburg Polytechnic University.