

АНАЛИЗ И СИНТЕЗ СИГНАЛОВ И ИЗОБРАЖЕНИЙ

УДК 004.032.26

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ДИФФЕРЕНЦИАЛЬНОЙ ДИАГНОСТИКИ ЛЁГОЧНЫХ ПАТОЛОГИЙ ПО РЕНТГЕНОЛОГИЧЕСКИМ ИЗОБРАЖЕНИЯМ

© С. М. Борзов¹, А. В. Карпов², О. И. Потатуркин¹, А. О. Хадзиев²

¹Институт автоматизации и электрометрии СО РАН,
630090, г. Новосибирск, просп. Академика Коптюга, 1

²Новосибирский научно-исследовательский институт туберкулёза Министерства
здравоохранения РФ,
630040, г. Новосибирск, ул. Охотская, 81А
E-mail: borzov@iae.nsk.su

Приведены исследования возможности создания интеллектуальных автоматизированных систем дифференциальной диагностики лёгочных заболеваний на основе идентификации патологических структур на рентгенологических изображениях (РИ) органов грудной полости (ОГП) с применением нейросетевых технологий. Представлен краткий анализ современных методик диагностики, и дано описание предлагаемого алгоритма определения типа патологий лёгочных тканей, используемого при визуальном анализе РИ и основанного на идентификации основных рентгенологических синдромов, а также на оценке количественных характеристик дифференциальной рентгенодиагностики. На примере классификации рентгенограмм здоровых и больных туберкулёзом пациентов продемонстрирована эффективность применения нейросетевых технологий при компьютерной диагностике лёгочных заболеваний. Исследования выполнены с применением общедоступной базы РИ ОГП, содержащей 3500 снимков здоровых и 3500 снимков больных людей.

Ключевые слова: цифровая обработка изображений, классификация, нейросетевые технологии, интеллектуальные системы, диагностика лёгочных заболеваний.

DOI: 10.15372/AUT20220307

Введение. Заболевания органов дыхания характеризуются широкой распространённостью и неуклонным ростом во всём мире. С учётом продолжающейся пандемии COVID-19 проблема диагностики заболеваний лёгких становится крайне актуальной. Рентгенологическое обследование, безусловно, является основным методом и неотъемлемой частью комплексной диагностики больных с лёгочными патологиями. Получаемые при этом данные в большинстве случаев оказываются решающими в установлении характера патологического процесса, а также в оценке его динамики, результатов лечения и последующих прогнозов. Поэтому при массовых обследованиях врачу-рентгенологу, как правило, приходится просматривать большое количество рентгенологических изображений (РИ), качество которых не всегда удовлетворительно, а разрешение относительно низкое. Такой анализ требует высокого профессионализма и предполагает умение распознавать даже самые малые изменения яркостей точек РИ с целью оценки объёма поражения лёгких [1], а также способность обнаруживать аномальные структуры. Эта работа весьма трудоёмкая и из-за особенностей субъективного зрительного восприятия изображений может приводить к ошибкам.

Современная рентгенология прошла большой путь развития от простой аналоговой трубки до мощных цифровых технологий. Разработка информационных систем поддержки принятия решений в этих исследованиях началась ещё в 50-е гг. прошлого века [2].

Сегодня на первое место в процессе автоматизации дифференциальной диагностики торакальной патологии выходят технологии, основанные на применении искусственного интеллекта (ИИ) и машинного обучения (МО) как его основной части. В настоящее время под ИИ принято понимать одно из направлений информационных технологий, которое связано с изучением и разработкой систем, моделирующих возможности человеческого интеллекта, таких как способность к обучению, логическому рассуждению, выводу и принятию решений [3].

Можно полностью согласиться с выводами многочисленных исследователей о том, что разработка интеллектуальных автоматизированных систем диагностики (ИАСД) является одним из подходов, способствующих качественной обработке данных лучевых обследований [4]. Актуальность современных исследований по разработке ИАСД неоспорима, прежде всего, с точки зрения мировых тенденций, особенно в период пандемии COVID-19. При этом основная задача врачей-исследователей заключается в анализе современных методик диагностики и формализованном описании алгоритмов классификации основных рентгенологических синдромов для определения типа патологий лёгочных тканей при визуальном анализе РИ.

В настоящее время в данной области ведутся активные исследования. В частности, создан сайт, представляющий пользователям наиболее передовые программные продукты для использования на практике [5]. В научной литературе имеется большое количество публикаций об успехах в решении указанной проблемы [6–9]. Несмотря на это, широкого внедрения разработанных программно-алгоритмических средств не происходит. На наш взгляд, в первую очередь это связано с попытками сразу разрабатывать и реализовывать автоматические интеллектуальные системы диагностики.

Сложность решаемой проблемы очевидна. Получаемые изображения для любого человека, не являющегося врачом-рентгенологом, очень трудно интерпретируемы. При решении задачи с применением искусственных нейронных сетей (ИНС) достигнуты определённые успехи. Как известно, их общим недостатком является возникающее переобучение. Так, при обучении на некотором конкретном наборе данных ИНС находят приемлемые по точности решения, однако при предъявлении им других серий аналогичных изображений, полученных в близких условиях и на похожей аппаратуре, результаты диагностики резко ухудшаются.

По этой причине в данной работе предлагается не традиционное решение задачи, основанное на диагностике заболеваний путём обучения ИНС на многочисленных примерах, а подход, использующий апробированный на практике при визуальной классификации патологий метод, основанный на дереве решений и использующий различные признаки на изображениях (обширное или ограниченное затенение, просветление и т. п.). Принятие решений в отдельных узлах дерева должно приниматься ИНС под контролем врача в интерактивном режиме. Постепенно адаптируясь к существующим условиям, сеть будет повышать достоверность своих решений, что позволит относиться к ним всё с большим доверием, вплоть до малейших отклонений в условиях регистрации или в особенностях заболевания.

Разработка и исследование эффективности алгоритмов дифференциальной диагностики лёгочных патологий на основе многослойных искусственных нейронных сетей глубокого машинного обучения являются принципиально важным шагом на пути создания интеллектуальных автоматизированных систем, позволяющих ускорить процесс диагностики заболеваний и снижающих долю повторных обследований.

Методика диагностики лёгочных патологий. Искусственный интеллект в настоящее время является высококонкурентной областью разработки технологий следующего поколения. Поэтому задача нашего исследования — это создание доступного программного продукта для самых массовых методик обследования в лучевой диагностике.

Для обследования пациентов с заболеваниями и повреждениями лёгких и органов средостения возможно использование различных лучевых методов и методик. Обычно обследование органов грудной полости (ОГП) начинается с классического рентгенологического исследования. На этом этапе применяются самые доступные основные рентгенологические методы: рентгенография, рентгенофлюорография, рентгеноскопия.

Рентгенография ОГП выполняется в виде обзорных снимков в прямой (обычно передней) и боковой (соответственно стороне поражения) проекциях с получением теневого изображения всех анатомических структур этой области. В стандартном варианте обследование производится в вертикальном положении пациента на высоте глубокого вдоха (с целью повышения естественной контрастности лёгких). Для детализации интересующих зон можно осуществить прицельные снимки. При цифровой рентгенографии ОГП соответствующая информация даётся в цифровой электронной форме и представляется на мониторе [10].

Рентгенофлюорография ОГП применяется главным образом для профилактических, массовых исследований в целях раннего выявления, прежде всего, туберкулёза и рака лёгких. Основное достоинство методики состоит в экономичности; пропускная способность составляет до 150 человек в час. Благодаря возможности получения крупнокадрового изображения (100 × 100 мм, 110 × 110 мм) флюорографию в настоящее время стали применять в качестве диагностической методики. Преимуществом рентгенографии и флюорографии является высокая разрешающая способность, объективная документация выявленных изменений, что позволяет достоверно судить об их динамике, сравнивая с предыдущими или последующими снимками.

Рентгеноскопия ОГП проводится только по строгим показаниям после анализа рентгенограмм и флюорограмм. Ограничение использования рентгеноскопии обусловлено значительной лучевой нагрузкой на пациента, отсутствием документальности, меньшей разрешающей способностью [11].

Учитывая, что в субъектах Российской Федерации широко распространены современные цифровые флюорографы, рентгенофлюорография в данной работе выбрана в качестве основного метода обследования ОГП.

Для классификации заболеваний по лучевым изображениям предлагается применять искусственные нейронные сети с машинным обучением, характерной чертой которого является не прямое решение, а обучение модели на многочисленных примерах решения сходных задач. При машинном обучении без участия человека осуществляется выявление внутренних (скрытых) закономерностей. На их основе обученная нейронная сеть в дальнейшем принимает решение об отнесении классифицируемых объектов к тому или иному классу. Чем больше обучающих данных обрабатывает такая сеть, тем точнее становится результат её работы.

Благодаря адаптивному характеру машинного обучения, оно хорошо соответствует сценариям, в которых данные постоянно изменяются, свойства запросов или задач нестабильны и разработка конкретных алгоритмов для решения задач диагностики практически невозможна, что мы и наблюдаем при интерпретации рентгенограмм и флюорограмм. Глубокое обучение — это специализированная форма машинного обучения, используемая для настройки параметров многослойных нейронных сетей, которые позволяют классифицировать информацию так же, как и человеческий мозг. Такие сети лежат в основе большинства современных систем ИИ.

Различные алгоритмы классификации РИ часто группируются по методам машинного обучения, которые в них используются: контролируемое обучение, неконтролируемое обучение и обучение с подкреплением. При контролируемом обучении алгоритмы обеспечивают прогнозирование на основе набора помеченных примеров. Эта методика может

использоваться при наличии таких примеров в достаточном количестве. Неконтролируемое обучение применяется, когда отсутствует информация о классах объектов обучающей выборки. Алгоритм помечает их автоматически на основе распределения в используемом признаковом пространстве.

В обучении с подкреплением применяются алгоритмы, которые имеют обратную связь и обучаются с использованием полученных результатов [12]. После каждого принятого решения алгоритм получает отзыв, помогающий определить, является ли сделанный выбор правильным, нейтральным или неправильным, и скорректировать его параметры. Это позволяет адаптировать алгоритм классификации под получаемые данные и приводит к постепенному увеличению его точности.

Для решения задачи дифференциальной диагностики лёгочных патологий по РИ необходимо выполнить сбор и подготовку данных, обучение модели, проверку модели с её дообучением и интерпретацию результатов. На первом этапе после набора РИ информация компилируется, в результате анализа обнаруживаются аномалии и устраняются проблемы с целостностью данных. На втором — РИ из подготовленных баз делятся на набор для обучения (обучающая выборка) и набор для тестирования. Обучающая выборка — это большая часть данных, которая используется для обучения модели нейронной сети. Второй набор применяется для оценки точности сети при обучении и по его завершении. В процессе обучения на вход модели в цикле подаются изображения из первого набора и по полученным результатам корректируются конфигурация и коэффициенты сети таким образом, чтобы её общая ошибка была минимальной. По завершении каждого цикла (эпохи обучения) осуществляется интегральная оценка точности классификации для обучающего и тестового наборов. С этой целью на вход модели с текущими коэффициентами последовательно подаются все изображения каждого набора и точность классификации определяется как доля правильно классифицированных РИ.

По окончании процедуры обучения оцениваются производительность и точность модели. Для этого на вход подаются вновь регистрируемые изображения и эффективность классификации проверяется врачом-рентгенологом. После обработки текущей серии РИ осуществляется дообучение ранее сформированной модели с использованием положительных и отрицательных примеров последней серии.

На этапе интерпретации полученные данные анализируются для определения работоспособности ИАСД и прогнозирования её эффективности.

Рентгенологические проявления патологических процессов в лёгких многообразны, но их основой являются всего лишь четыре феномена: затемнение или просветление лёгочных полей, изменение лёгочного рисунка, изменение корней лёгких. Выявив на РИ эти патологические изменения, можно определить их соответствие рентгенологическим синдромам.

В рентгенологии выделяют девять синдромов [13], отображающих практически всю многообразную патологию органов дыхания (рис. 1):

- 1) тотальное (субтотальное) затемнение лёгочного поля,
- 2) ограниченное затемнение,
- 3) круглая тень,
- 4) кольцевидная тень (круглая полость),
- 5) очаги и ограниченные очаговые диссеминации,
- 6) обширные очаговые диссеминации,
- 7) обширное просветление,
- 8) изменение лёгочного рисунка,
- 9) изменение корней лёгких.




Рис. 1. Основные рентгенологические синдромы поражения дыхательной системы: 1 — тотальное (субтотальное) затемнение лёгочного поля, 2 — ограниченное затемнение, 3 — круглая тень, 4 — кольцевидная тень (круглая полость), 5 — очаги и ограниченные очаговые диссеминации, 6 — обширные очаговые диссеминации, 7 — обширное просветление, 8 — изменение лёгочного рисунка, 9 — изменение корней лёгких

Первоначально необходимо разделить РИ на группы, соответствующие девяти указанным синдромам, а затем работать с каждой группой отдельно. Таким образом должна быть проведена внутрисиндромная диагностика, определён общий характер патологического процесса, установлена конкретная форма заболевания. Согласно этим синдромам осуществляется сортировка рентгенограмм без патологий и по различным признакам торакальной патологии, а затем отбираются эталонные РИ (без сочетанной патологии) по 100–300 рентгенограмм по каждому признаку (с последующим увеличением их количества).

В рентгенологии достаточно успешно и активно применяется алгоритм «дерево решений». Этот тип алгоритмов является одним из наиболее эффективных инструментов интеллектуального анализа данных и предсказательной аналитики, которые позволяют решать задачи классификации. Они представляют собой иерархические древовидные структуры, состоящие из решающих правил вида «если ..., то ...» и осуществляющие проверку соответствия анализируемых РИ по какому-либо признаку обучающего множества. Пример алгоритма дифференциальной рентгенодиагностики болезней при синдроме обширного затемнения приведён на рис. 2 (органы средостения не смещены — смещены, в сторону затемнения — в противоположную и т. д.).

По такому же принципу производится формирование деревьев решений по другим синдромам торакальной патологии. Дополнительно в алгоритм диагностики закладывается механизм определения синдрома формирования полости по основным рентгенологическим параметрам (рис. 3).

Предложенный подход целесообразно использовать для разработки программно-алгоритмического обеспечения дифференциальной автоматизированной диагностики таких сложных лёгочных заболеваний, как туберкулёз, различные формы которого сочетают




Рис. 2. Алгоритм дифференциальной рентгенодиагностики болезней лёгких при синдроме обширного затемнения




Рис. 3. Стадии формирования полости: *a* — формирующаяся полость, *b* — сформированная свежая (эластическая) полость, *c* — старая (фиброзная) полость




Рис. 4. Формы туберкулёза лёгких в рентгенологическом изображении: *a* — первичный туберкулёзный комплекс, *b* — туберкулёз внутригрудных лимфатических узлов (инфильтративная форма), *c* — туберкулёз внутригрудных лимфатических узлов (туморозная форма), *d* — очаговый туберкулёз лёгких, *e* — милиарный туберкулёз, *f* — диссеминированный туберкулёз, *g* — инфильтративный туберкулёз (лобит), *h* — инфильтративный туберкулёз в фазе распада

разные рентгенологические синдромы (рис. 4). При этом необходимо учитывать результаты интерпретации врачами-рентгенологами.

Таким образом, для создания интеллектуальных систем классификации лёгочных патологий по рентгенологическим изображениям на основе дерева решений, реализуемого с применением многослойных нейронных сетей глубокого машинного обучения, необходимо формирование баз данных для обучения основным синдромам и частным признакам дифференциальной рентгенодиагностики. По каждому признаку необходимо иметь несколько сотен положительных примеров с последующим увеличением их количества в процессе работы ИНС под контролем врачей-рентгенологов.

Экспериментальные исследования. Для демонстрации эффективности применения нейросетевых технологий при диагностике лёгочных заболеваний приведём пример различения рентгенограмм здоровых и больных туберкулёзом людей. Исследования выполнены с применением общедоступной базы РИ ОГП, созданной группой исследователей из Катарского университета (Доха, Катар) и Университета Дакки (Бангладеш) вместе с коллегами из Малайзии в сотрудничестве с врачами из Бангладеш и Медицинской корпорации Хамад [14]. Данная база содержит 3500 снимков здоровых и 3500 снимков больных людей. Отметим, что этой группе учёных удалось классифицировать РИ туберкулёза и нормальной грудной клетки с точностью 98,6 % [15].

В качестве ИНС применялась предообученная на наборе изображений ImageNet модель сети AlexNet из библиотеки PyTorch [16], которая состоит из пяти свёрточных слоёв, последовательно осуществляющих свёртку РИ с небольшим ядром, и трёх полносвязных, выполняющих собственно классификацию.

Все изображения случайным образом были разделены на два набора. Первый из них использовался для дополнительного обучения модели сети, второй — для оценки её точно-

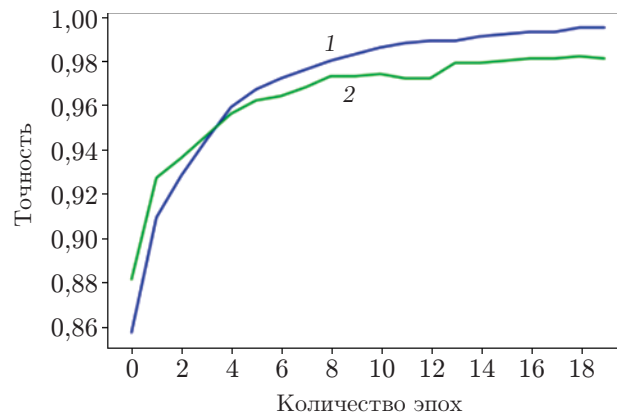


Рис. 5. Точность сети на различных этапах обучения: кривая 1 — для обучающего набора, кривая 2 — для тестового

сти в процессе и по завершении этой процедуры. При этом настраивание весовых коэффициентов осуществлялось только для трёх полносвязных слоёв классификатора. В процессе обучения на вход модели в цикле подавались РИ из первого набора и по результатам её работы коэффициенты корректировались таким образом, чтобы общая ошибка сети была минимальной. По завершении каждого цикла предъявления обучающих примеров (эпохи обучения) осуществлялась интегральная оценка точности классификации для обучающего и тестового наборов. С этой целью на вход модели с текущими коэффициентами последовательно подавались все изображения каждого набора и точность классификации определялась как доля правильно классифицированных РИ. Обучение было ограничено 20 эпохами. Точности, полученные в процессе выполнения изложенных процедур (после каждой эпохи обучения), показаны на рис. 5.

Видно, что в процессе обучения точность классификации как обучающего, так и тестового набора РИ от эпохи к эпохе растёт и достигает значений в первом случае 99,5 %, во втором — 98 %. Из этого следует, что результирующая модель способна с указанной точностью отличать РИ здоровых и больных людей. Важным при этом является, чтобы предъявляемые для диагностики изображения относились к тем же формам туберкулёза и содержали схожие рентгенологические синдромы, что и РИ обучающего набора. Обязательным условием также является соответствие форматов и параметров данных.

В приведённом эксперименте это требование соблюдается, поскольку обучающий и тестовый наборы были сформированы из одного набора. В общем случае оно может и не выполняться. В частности, РИ, полученные на различном оборудовании, могут иметь различную яркость, контрастность и разрядность данных, а также искажённую нелинейным образом передаточную характеристику. Для уменьшения влияния последнего фактора на точность классификации перед предъявлением изображений на вход модели осуществлялось их приведение к одинаковым пространственному разрешению и разрядности, а также преобразование яркости путём согласования гистограмм.

Пример результата работы модели ИНС для восьми изображений, зарегистрированных с помощью оборудования СО РАН ГАУЗ ГКБ № 1, ГБУЗ БЦГБ г. Бердска, ООО МСЧ ВЕГА г. Бердска, приведён на рис. 6. Здесь для каждого изображения указан номер выбранного моделью класса и достоверность принятого решения в процентах.

В данном случае использовались четыре изображения с явными признаками туберкулёза (рис. *b, c, f, g*), два без патологий (рис. *a, h*) и два (рис. *d, e*) с другими отклонениями, отличными от туберкулёза. Анализ результатов показывает, что обученная на общедоступной базе РИ [8] модель успешно решила задачу диагностики для семи из предъ-




Рис. 6. Результат работы модели для восьми изображений: *a* — класс 1 (88,58 %), *b* — класс 2 (91,32 %), *c* — класс 2 (91,52 %), *d* — класс 1 (88,62 %), *e* — класс 1 (64,41 %), *f* — класс 2 (89,53 %), *g* — класс 1 (67,50 %), *h* — класс 1 (97,82 %)

явленных изображений. Ошибка допущена лишь на одном из них (рис. *g*), содержащем небольшой слабоконтрастный кальцинат в районе второго ребра в левой части лёгкого, трудно обнаруживаемый и при визуальном наблюдении. При этом применение такой модели ИНС для классификации набора из 50 изображений, полученных с помощью этого же оборудования на начальных стадиях заболевания (со слабо выраженными симптомами), показало, что она с решаемой задачей не справляется.

Заключение. Создание объёмных баз данных рентгенологических изображений позволяет перейти к разработке интеллектуальных систем дифференциальной диагностики лёгочных патологий с контролем показателей их эффективности.

Предложено в таких системах использовать для определения типа патологий лёгочных тканей древовидный алгоритм, применяемый врачом-диагностом при визуальном анализе РИ и основанный на идентификации базовых рентгенологических синдромов и на оценке количественных характеристик патологических структур. Он представляет собой иерархическую древовидную структуру, состоящую из решающих правил вида «если . . . , то . . . ». Решающие правила в каждом узле осуществляют проверку соответствия РИ какому-либо критерию на основе бинарной классификации с применением нейросетевых технологий. Представлено формализованное описание алгоритма определения типа патологий лёгочных тканей.

На примере классификации РИ здоровых и больных туберкулёзом людей продемонстрирована эффективность применения нейросетевых технологий для диагностики лёгочных заболеваний. Экспериментальные исследования, выполненные с применением общедоступной базы РИ грудной клетки, позволили достичь точности классификации, превышающей 98 %. При этом важно, чтобы предъявляемые для диагностики изображения относились к тем же формам туберкулёза и содержали схожие рентгенологические синдромы, что и изображения обучающей выборки.

Отметим, что обучение ИНС требует достаточно длительного времени. Так, на компьютере (процессор Intel Core i3 3.60 Гц, оперативная память 16.0 Гб, без GPU) 20 эпох обучения сети AlexNet на наборе из 7000 изображений заняли около 50 мин. Однако сама процедура диагностики одного РИ выполняется за сотые доли секунды.

Полученные результаты целесообразно использовать при разработке автоматизированных интеллектуальных систем дифференциальной диагностики лёгочных заболеваний с применением многослойных нейронных сетей. Это даёт возможность создавать клинически значимые приложения, осуществляющие анализ общих закономерностей заболеваний, корреляционный анализ выявляемых симптомов и генерацию рентгенологических отчётов.

Благодарность. Автор выражает благодарность д. т. н. Е. С. Нежевенко за полезные обсуждения.

Финансирование. Работа выполнена при поддержке Министерства науки и высшего образования в рамках выполнения работ по Государственному заданию № 121022000116-0 в ИАиЭ СО РАН.

СПИСОК ЛИТЕРАТУРЫ

1. **Howard J.** Cognitive Errors and Diagnostic Mistakes. A Case-based Guide to Critical Thinking in Medicine. New York: Springer, 2019. 588 p.
2. **Блинов Н. Н., Владимиров Л. В., Кочетова Г. П. и др.** Рентгенодиагностические аппараты. М.: Медицина, 1976. 240 с.
3. **Мелдо А. А., Уткин Л. В.** Обзор методов машинного обучения в диагностике рака лёгкого // Искусственный интеллект и принятие решений. 2018. № 3. С. 28–38.
4. **Мелдо А. А., Уткин Л. В., Трофимова Т. Н.** Искусственный интеллект в медицине: современное состояние и основные направления развития интеллектуальной диагностики // Лучевая диагностика и терапия. 2020. 11, № 1. С. 9–17.
5. **AI Products** for Tuberculosis Healthcare. AI4HLTH. Stop TB Partnership. URL: <https://www.ai4hlth.org/> (дата обращения: 14.04.2022).
6. **Duong L. T., Le N. H., Tran T. B. et al.** Detection of tuberculosis from chest X-ray images: Boosting the performance with vision transformer and transfer learning // Expert Syst. with Applications: An Int. Journ. 2021. 184, N C. DOI: 10.1016/j.eswa.2021.115519.
7. **Dasanayaka S., Dissanayake M. B.** Deep learning methods for screening pulmonary tuberculosis using chest X-rays // Comp. Meth. in Biomech. and Biomed. Eng.: Imag. & Vis. 2021. 9, Iss. 1. P. 39–49.
8. **Yadav S. S., Jadhav S. M.** Deep convolutional neural network based medical image classification for disease diagnosis // Journ. Big Data. 2019. 6, Iss. 1. P. 1–18.
9. **Guan Q., Huang Y.** Multi-label chest X-ray image classification via category-wise residual attention learning // Pattern Recogn. Lett. 2020. 130, Iss. C. P. 259–266.
10. **Трофимова Т. Н., Бельчикова Н. С., Голимбиевская Т. А.** Лёгочный рисунок в норме и при патологических процессах в лучевом изображении. С.-Пб.: СПбМАПО, 2001. 37 с.
11. **Ищенко Б. И., Бисенков Л. Н., Тюрин И. Е.** Лучевая диагностика для торакальных хирургов. С.-Пб.: Деан, 2001. 346 с.
12. **Боровик В. С., Шидловский С. В.** Обучение с подкреплением в системах управления объектами с транспортным запаздыванием // Автометрия. 2021. 57, № 3. С. 48–57. DOI: 10.15372/AUT20210306.
13. **Линденбратен Л. Д., Наумов Л. Б.** Медицинская рентгенология. М.: Медицина, 1984. С. 73–83, 170–190.

-
14. **Tuberculosis (TB) Chest X-ray Database.** Kaggle Weblink. The largest TB Chest X-ray Database /Т. Rahman, M. Chowdhury, A. Khandakar. URL: <https://www.kaggle.com/tawsifurrahman/tuberculosis-tb-chest-xray-dataset> (дата обращения: 18.02.2022).
 15. **Rahman T., Khandakar A., Kadir M. A. et al.** Reliable tuberculosis detection using chest X-ray with deep learning, segmentation, and visualization // IEEE Access. 2020. **8**. P. 191586–191601. DOI: 10.1109/ACCESS.2020.3031384.
 16. **PyTorch.** Официальный сайт PyTorch. URL: <https://pytorch.org/> (дата обращения: 14.01.2022).

Поступила в редакцию 22.03.2022

После доработки 20.04.2022

Принята к публикации 28.04.2022
