

УДК 004.932.2

DOI: [10.26102/2310-6018/2020.29.2.030](https://doi.org/10.26102/2310-6018/2020.29.2.030)

Повышение качества и оперативности идентификации специальных состояний мониторируемых объектов на основе разработки математического и программного обеспечения обработки компьютерных изображений с использованием больших баз данных

В. А. Васильченко, В. Л. Бурковский

ФГБОУ ВО «Воронежский государственный технический университет»,
Воронеж, Российская Федерация

Резюме: Актуальность исследования обусловлена нарастанием заболеваний человека, которые ассоциированы со значительным социально-экономическим ущербом и дающие значительную нагрузку на здравоохранение. В соответствии с рекомендациями ВОЗ система профилактики заболеваний должна включать в себя оценку распространенности, коррекцию, а также контроль факторов риска (WHO, 2009). Особое место в этом комплексе мер занимает система массового мониторинга заболеваний, как механизм оценки ситуации и потребности в реализации профилактических мер, так и способ контроля эффективности реализуемых профилактических мероприятий. В связи с этим данная статья рассматривает создание алгоритма обработки снимков компьютерного томографа легких человека с помощью программного обеспечения. Ведущим методом к исследованию данной проблемы являются нейронные сети. В статье представлена сверточная нейросетевая модель Chexnet обработки рентгеновских снимков, разработанная учеными из стэнфордского университета. Рассмотрен алгоритм разработки механизма анализа снимков на основе современных рентгеновских снимков органов – снимков компьютерной томографии, которые получают с помощью сложного программно-технического комплекса, имеющего сверхчувствительные детекторы для регистрации рентгеновского излучения, а также обширный пакет программного обеспечения, позволяющий получить снимки с высоким пространственным разрешением. Разработанный алгоритм реализован на основе сверточной сети Densenet, глубина которой составляет 201 слой. В него были внесены изменения в виде применения функции активации ReLU (сокращение от англ. rectified linear unit), которая позволяет существенно ускорить процесс обучения и одновременно с этим значительно упростить вычисления. Как результат, разработанная сверточная нейронная сеть помогает непрерывности сбора данных, что позволяет совершенствовать процесс принятия стратегических решений, разрабатывать программы действий в области общественного здравоохранения.

Ключевые слова: компьютерная обработка изображений, сверточная нейронная сеть, DenseNet, карта признаков, функция активации ReLU, диагностика заболеваний.

Для цитирования: Васильченко В. А., Бурковский В. Л. Повышение качества и оперативности идентификации специальных состояний мониторируемых объектов на основе разработки математического и программного обеспечения обработки компьютерных изображений с использованием больших баз данных. *Моделирование, оптимизация и информационные технологии*. 2020;8(2). Доступно по: https://moit.vivt.ru/wp-content/uploads/2020/05/VasilchenkoBurkovsky_2_20_2.pdf DOI: 10.26102/2310-6018/2020.29.2.030

Improving the quality and efficiency of identification of special states of monitored objects based on the development of mathematical and software for processing computer images using large databases

V.A. Vasilchenko, V.L. Burkovsky

FSBE of HE "Voronezh State Technical University"

Abstract: The relevance of the study is due to an increase in human diseases, which are associated with significant socio-economic damage and give a significant burden on health. According to WHO recommendations, a disease prevention system should include prevalence assessment, correction, and risk factor management (WHO, 2009). A special place in this set of measures is occupied by the mass disease monitoring system, both a mechanism for assessing the situation and the need for implementing preventive measures, and a method for monitoring the effectiveness of implemented preventive measures. In this regard, this article considers the creation of an algorithm for processing images of a computer tomography scan of a human lung using software. The leading method to study this problem are neural networks. The article presents a convolutional neural network model of Chexnet X-ray processing developed by scientists from Stanford University. An algorithm for developing a mechanism for analyzing images based on modern x-ray images of organs - computed tomography images, which are obtained using a complex software and hardware complex with ultra-sensitive detectors for recording x-ray radiation, as well as an extensive software package that allows you to obtain images with high spatial resolution, is considered. The developed algorithm is implemented on the basis of the Densenet convolution network, the depth of which is 201 layers. Changes were made to it in the form of using the ReLU activation function (short for English rectified linear unit), which can significantly speed up the learning process and at the same time significantly simplify calculations. As a result, the developed convolutional neural network helps the continuity of data collection, which allows to improve the process of strategic decision-making, to develop action programs in the field of public health.

Keywords: computer image processing, convolutional neural network, DenseNet, feature map, ReLU activation function, disease diagnosis.

For citation: Vasilchenko V.A., Burkovsky V.L. Improving the quality and efficiency of identification of special states of monitored objects based on the development of mathematical and software for processing computer images using large databases. *Моделирование, оптимизация и информационные технологии*. 2020;8(2). Доступно по: https://moit.vivt.ru/wp-content/uploads/2020/05/VasilchenkoBurkovsky_2_20_2.pdf DOI: 10.26102/2310-6018/2020.29.2.030 (In Russ).

Введение

Современные компьютерные томографы (КТ) имеют возможность производить снимки с высоким пространственным разрешением. Время такого обследования занимает считанные минуты. Однако процесс обработки и анализа снимков, а также получение заключения требуют гораздо больше времени. Более того, анализ изображения компьютерного томографа требует высокой квалификации врача.

В связи с этим становится актуальной задача повышение качества и скорости проведения обследований путем автоматизации процесса анализа изображений КТ с помощью программного комплекса.

Первоочередной задачей алгоритмизации процесса распознавания состояний физиологических объектов является определение их нормального строения, а также возможных вариантов отклонения от нормы.

Изображение органов на снимках компьютерного томографа представляется в виде участков низкой плотности (темный цвет) и участков высокой плотности (светлый цвет).

Материалы и методы

Анализ изображения позволяет выделить обследуемый орган, а также сосуды, мышечную и костную ткань (рисунок 1).

В настоящий момент уже проведена обширная работа по разработке алгоритмов и методик обработки изображений для явного выделения отличительных признаков, характерных для пациентов [1, 2].



Рисунок 1 – Снимок человека, сделанный с помощью компьютерного томографа
Figure 1 – A snapshot of a person taken with a computer tomograph

Тем не менее, все эти процессы связаны со значительными затратами времени и усилий. Для дальнейшего повышения точности предсказаний требуются огромные объемы маркированных данных. Обработка изображений и выделение отличительных признаков в наборах данных изображений – весьма сложный и длительный процесс.

Интерпретация рентгеновских снимков для диагностики патологий легких – достаточно трудоемкий процесс, вследствие чего в диагнозах часто бывают разночтения. Поэтому возникла идея создания алгоритма машинного обучения, способного ставить точные диагнозы на основе сотен тысяч изученных снимков.

Рентгенография грудной клетки в настоящее время является лучшим доступным методом диагностики пневмонии, которая играет значительную роль в клинической помощи и эпидемиологических исследованиях. Однако обнаружение пневмонии на рентгеновских снимках грудной клетки является сложной задачей, которая зависит от наличия экспертов–радиологов.

Выявление какой–либо закономерности в расположении того или иного рисунка исследуемого органа является главной задачей процесса диагностики.

Возникновение пневмонии в рентгеновских снимках часто расплывчато, может перекрываться с другими диагнозами, и может имитировать многие другие доброкачественные аномалии. Эти особенности вызывают значительные расхождения среди радиологов в диагностике пневмонии.

Алгоритм сверточной нейронной сети Chexnet, разработанный учеными из стэнфордского университета, локализует патологии, идентифицируя их с помощью карт активации класса, которые выделяют области на снимке наиболее важные для

классификации конкретных патологий [3]. CheXnet правильно обнаруживает пневмонию, а также локализует области изображения, наиболее показательные для патологии.

Модель CheXNet представляет собой свернутую нейронную сеть на 121 слой, которая получает снимок грудной клетки и выводит вероятность пневмонии с тепловой картой, локализуя области изображения, наиболее показательные для пневмонии.

Использовались методы глубокого обучения и пакетной нормализации. суть метода состоит в том, что некоторым слоям нейронной сети на вход подаются данные, которые предварительно обработаны и имеют нулевое математическое ожидание и единичную дисперсию.

Выборку из 420 снимков из ChestX-ray14 анализировали 4 высококвалифицированных радиолога и разработанная нейронная сеть. У радиологов был опыт 4, 7, 25 и 28 лет соответственно. Радиологи не имели доступа к какой-либо информации о пациенте или информации о распространенности заболевания в данных. Обнаружение пневмонии при рентгенографии грудной клетки сильно затруднительно для радиологов.

Было установлено, что алгоритм превышает среднюю эффективность радиолога в задаче обнаружения пневмонии. Также был проведен анализ сравнения CheXNet с другими алгоритмами по диагностике на основе базы снимков ChestX-ray14 [4]. сравнение на основе метрики F-меры, которая основана на точности и полноте оцениваемой модели, приведено в таблице 1. CheXNet достигает значения F-меры 0,435 (95% cI I 0.387, 0.481), что выше, чем средний радиолог 0,387 (95% cI I 0.330, 0.442).

Возникла идея разработки подобного механизма анализа снимков на основе более современных рентгеновских снимки органов – снимков компьютерной томографии, которые получают с помощью сложного программно-технического комплекса, имеющего сверхчувствительные детекторы для регистрации рентгеновского излучения, рентгеновские излучатели, обширный пакет программного обеспечения, позволяющий получить снимки с высоким пространственным разрешением [5].

За основу был взят алгоритм сверточной сети Densenet, глубина которого составляет 201 слой [6]. В него были внесены изменения в виде применения функции активации ReLU (сокращение от англ. rectified linear unit), которая позволяет существенно ускорить процесс обучения и одновременно с этим значительно упростить вычисления (за счёт простоты самой функции). По состоянию на 2017 год эта функция и её модификации (Noisy ReLU, Leaky ReLU и другие) являются наиболее часто используемой функцией активации в глубоких нейросетях, в частности, в свёрточных.

Также, для обеспечения максимального потока информации между слоями в сети, были соединены все слои напрямую друг с другом (с соответствующими размерами карт характерных признаков). Важным отличием от DensNet также является то, что передача передачей в следующий слой не происходит объединения признаков посредством суммирования, а происходит объединения посредством соединения их.

Следовательно, слой l^{th} имеет l входов, состоящий из карт признаков всех предыдущих сверточных блоков. Его собственные карты свойств передаются всем последующим слоям. Это приводит к $\frac{L(L+1)}{2}$ соединениям в L -слоистой сети, вместо

L соединений, как в традиционной архитектуре [7].

Возможно, нелогичным эффектом Dense-соединений является то, что требуется меньше параметров, чем в традиционных сверточных сетях, поскольку нет необходимости переобучать карты признаков. Традиционные архитектуры прямой связи

можно рассматривать как алгоритмы с состоянием, которое передается от слоя к слою. Каждый уровень считывает состояние с предыдущего уровня и записывает на последующий уровень. Он изменяет состояние, но также передает информацию, которую необходимо сохранить. Некоторые варианты DenseNets показывают, что многие слои вносят очень небольшой вклад и фактически могут быть случайно отброшены во время обучения [8]. Это делает состояние DenseNets схожим с (развернутыми) рекуррентными нейронными сетями, но число параметров DenseNets существенно больше, поскольку каждый слой имеет свои веса. Предлагаемая модифицированная архитектура DenseNet четко различает информацию, которая добавляется в сеть, и информацию, которая сохраняется. В архитектуре DenseNet были установлены узкие слои (например, 12 фильтров на слой). При этом, добавляя лишь небольшой набор карт характеристик к «коллективным знаниям» сети и оставляя неизменными карты характеристик, окончательный классификатор принимает решение на основе всех карт признаков в сети. Помимо лучшей эффективности параметров, одним большим преимуществом модифицированной DenseNets является улучшенный поток информации и градиентов по всей сети, что облегчает их обучение. Каждый слой имеет прямой доступ к градиентам из функции потерь и исходного входного сигнала, что ведет к неявному глубокому надзору.

l^{th} слой модифицированной DenseNets получает карты признаков всех предыдущих уровней x_0, \dots, x_{l-1} в качестве входа:

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (1)$$

где, $[x_0, x_1, \dots, x_{l-1}]$ относится к объединению карт объектов, созданных в слоях $0, \dots, l-1$.

Композитная функция. Определение H_l происходит, как составная функция трех последовательных операций: пакетная нормализация (batch normalization (BN)), применение функции ReLU (rectified linear unit) и свертки 3×3 (conv).

Слои пулинга. Операция конкатенации, используемая в формуле (1) не является жизнеспособным, когда размер карт характеристик изменяется. Однако существенной частью сверточных сетей являются слои понижающей дискретизации, которые изменяют размер карт признаков. Для облегчения понижающей дискретизации в модифицированной архитектуре, сеть разделяется на несколько Dense-блоков – рисунок 2.

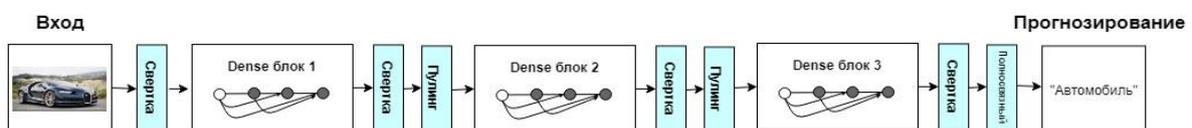


Рисунок 2 – Пример модифицированной DenseNet с тремя Dense блоками. Слои между двумя смежными блоками называются переходными слоями и изменяют размеры карты объектов посредством свертки и объединения

Figure 2 - An example of a modified DenseNet with three Dense blocks. The layers between two adjacent blocks are called transition layers and resize the map of objects by convolution and merging.

Слои между блоками называются переходными слоями, которые выполняют свертку и объединение. Переходные слои, используемые в алгоритме диагностики,

состоят из пакетного нормализационного слоя и сверточного слоя 1x1, за которым следует средний пулирующий слой 2x2.

Скорость роста. Если каждая функция H_l предоставляет k карт признаков, то отсюда следует, что l^{th} слой имеет $k_0 + k \times (l-1)$ карт признаков, где k_0 – количество каналов во входном слое. Важным отличием модифицированного DenseNet является то, что он может иметь очень узкие слои, например, $k = 12$. Параметр k называется скоростью роста сети. Относительно небольшая скорость роста достаточна для получения достоверных результатов. Одним из объяснений этого является то, что каждый уровень имеет доступ ко всем предшествующим картам характеристик в своем блоке и, следовательно, к «коллективным знаниям» сети. Можно рассматривать карты признаков как глобальное состояние сети. Каждый слой k добавляет к этой карте свои собственные карты объектов. Скорость роста определяет, сколько новой информации каждый слой вносит в глобальное состояние. После однократного записывания глобального состояния, к нему можно получить доступ из любой точки сети, и, в отличие от традиционных сетевых архитектур, нет необходимости копировать его из слоя в слой.

Свертка. Чтобы еще больше улучшить компактность модели, требуется уменьшить количество карт признаков на переходных слоях. Если dense блок содержит m карт признаков, то следующему переходному слою необходимо сгенерировать выходные θm карты признаков, где $0 < \theta \leq 1$, называемое коэффициентом сжатия. Когда $\theta = 1$, количество карт признаков через переходные слои остается неизменными. В модифицированной DenseNet параметр θ был установлен 0,5.

Результаты

Детали реализации. Модифицированная DenseNet имеет четыре Dense блока (в оригинальной сети DenseNet использовалось три блока), каждый из которых имеет одинаковое количество слоев. Перед входом в первый dense блок на входных изображениях выполняется свертка с 16 выходными каналами. Для сверточных слоев с размером ядра 3x3 каждая сторона входов дополнена нулями на один пиксель, чтобы сохранить размер карты объектов фиксированным. Использовалась свертка 1x1 с последующим слоем пуллинга 2x2 между двумя смежными dense блоками. В конце последнего dense блока выполнялся глобальный пулинг, а затем присоединялся классификатор softmax. Точная конфигурация сети представлена в таблице 3.

Каждый слой принимает все предыдущие карты объектов в качестве входных данных. Первоначальный вариант сети позволял классифицировать порядка 1000 различных категорий объектов. Применение метода переноса обучения в глубоких нейронных сетях позволило использовать предварительно обученную сеть в качестве отправной точки для классификации легочных патологий – рисунок 3.

Реструктурированная базовая сверточная нейронная сеть Densenet-201 представляет собой свернутую нейронную сеть на 201 слой, которая получает снимок КТ легких и выводит вероятность легочного заболевания с тепловой картой, локализирующей области изображения, наиболее показательные для пневмонии. Обучение сети происходило на современном наборе снимков SIMBA, который включает в себя 20 000 документированных снимков, содержащих детальную медицинскую информацию о каждом из них, в том числе описание заболевания с указанием очага на снимке. Использовались методы глубокого обучения и batch normalization для оптимизации, разрабатываемой сверточной нейронной сети.

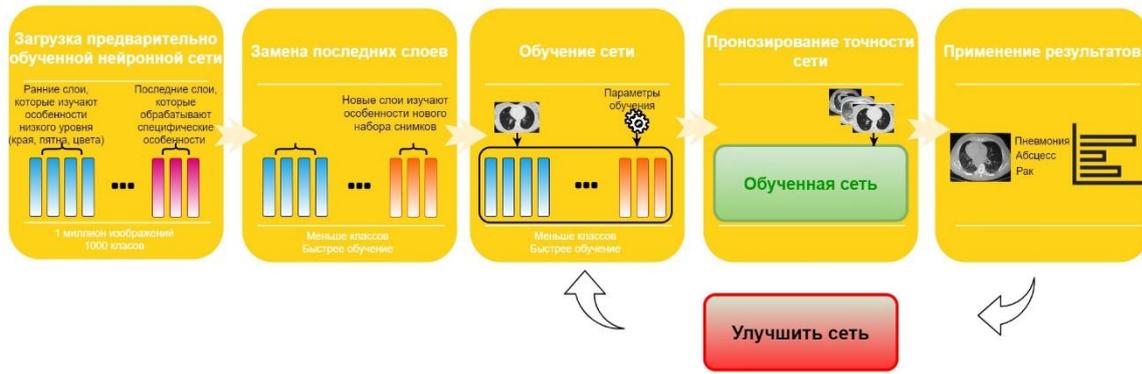


Рисунок 3 – Реструктуризация базовой обученной нейронной сети
Figure 3 - Restructuring of a basic trained neural network

Сверточный слой должен принадлежать диапазону значений $[1;3]$, слой субдескрипции – $[0;1]$, полносвязный слой – $[0;2]$. Увеличение размера и сложности входного изображения должно увеличивать размер сверточного слоя. Также должны быть использованы максимальные значения количества сверточных слоев и слоев субдескрипции при минимальном количестве полносвязных слоев.

Обсуждение

Данные рекомендации были использованы при построении сверточной нейронной сети диагностики заболеваний, архитектура которой представлена также в таблице 1.

Возможен опциональный ввод основных и дополнительных параметров сети. В результате будет получен набор архитектур сверточных нейронных сетей, которые будут эффективными для поставленной задачи, а также будут иметь высокий класс точности.

Диагностика пневмонии является задачей бинарной классификации рентгеновских снимков, где на вход подается изображение легких X , а на выходе бинарные значения $y \in \{0,1\}$, которые указывают на отсутствие или наличие пневмонии соответственно.

Таблица 1 Архитектура предлагаемой сверточной нейронной сети
Table 1 Architecture of the proposed convolutional neural network

слои	Выходной размер	сеть
сверточный	112x112	$7 \times 7 \text{ conv}$, глубина 4
субдескрипции	56x56	$3 \times 3 \text{ max pool}$, глубина 4
Dense блок (1)	56x56	$[1 \times 1 \text{ conv}] \times 6$ $[3 \times 3 \text{ conv}]$
Переходной слой (1)	56x56	$1 \times 1 \text{ conv}$
	28x28	$2 \times 2 \text{ avr pool}$, глубина 2
Dense блок (2)	28x28	$[1 \times 1 \text{ conv}] \times 12$ $[3 \times 3 \text{ conv}]$
Переходной слой (2)	28x28	$1 \times 1 \text{ conv}$
	14x14	$2 \times 2 \text{ avr pool}$, глубина 2
Dense блок (3)	14x14	$[1 \times 1 \text{ conv}] \times 24$ $[3 \times 3 \text{ conv}]$
Переходной слой (3)	14x14	$1 \times 1 \text{ conv}$
	7x7	$2 \times 2 \text{ avr pool}$, глубина 2

Dense блок (4)	7x7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$
слой классификации	1x1	7x7 global average pool
		1000D полносвязный слой. Softmax

Для одного примера в обучающем наборе производится оптимизация взвешенной бинарной кросс-энтропийной потери

$$L(X, y) = -w_+ \cdot y \log p(Y = 1 | X) - w_- \cdot (1 - y) \log p(Y = 0 | X) \quad (2)$$

где $p(Y = i | X)$ – вероятность того, что сеть назначит значение i , $w_+ = |N| / (|P| + |N|)$, и $w_- = |P| / (|P| + |N|)$, при $|P|$ и $|N|$ – число положительных случаев и отрицательных случаев пневмонии в тренировочном наборе соответственно.

$$L(X, y) = \sum_{c=1}^{14} [-y_c \log p(Y_c = 1 | X) - (1 - y_c) \log p(Y_c = 0 | X)], \quad (3)$$

где $p(Y_c = 1 | X)$ – предсказанная вероятность того, что изображение содержит патологию C и $p(Y_c = 0 | X)$ – предсказанная вероятность того, что изображение не содержит патологии C .

Заключение

В результате модифицированный алгоритм был протестирован на снимках компьютерного томографа легочных долей человека. Обучение проводилось на обработанных изображениях разрешением 224×224 пикселей. Объем обучающей выборки составил 15000 изображений от 50 пациентов [9].

Обучение нейронной сети производилось методом обратного распространения ошибки, заключающийся в повороте ядра на 180 градусов и скользящем процессе сканирования сверточной карты дельт с измененными краевыми эффектами.

Расчет ошибки на сверточном слое происходит на основе вычисления дельты текущего слоя (сверточного) за счет знаний о дельтах подвыборочного слоя. В результате чего нет необходимости вычислять дельту ошибки – достаточно ее скопировать. При прямом распространении сигнала нейроны подвыборочного слоя формируются за счет сканирования по сверточному слою, в процессе которого выбираются нейроны с максимальным значением. При обратном распространении возвращается дельта ошибки максимальному нейрону, который был ранее выбран, а остальные получают значение нулевой дельты ошибки.

ЛИТЕРАТУРА

1. Беликова Т.П. *Моделирование линейных фильтров для обработки рентгеновских изображений в задачах медицинской диагностики. Цифровая оптика. Обработка изображений и полей в экспериментальных исследованиях.* М.: Наука, 1990.
2. Гонсалес Р. *Цифровая обработка изображений:* пер. с англ. Р. Гонсалес, Р. Вудс. – М.: Техносфера, 2005
3. Труфанов Г.Е., Рязанов В.В., Дергунова Н.И. и др. *Совмещенная позитронно-эмиссионная и компьютерная томография (ПЭТ-КТ) в онкологии.* Элби-сПб, 2005

4. Deng, Jia, Dong, Wei, Socher, Richard, Li, Li–Jia, Li, Kai, and Fei–Fei, Li. Imagenet: A large–scale hierarchical image database. *In Computer Vision and Pattern Recognition*, 2009;248–255.
5. Мистюков Б.В., Бурковский В.Л. Нейросетевое моделирование динамики нелинейных систем. *Вестник воронежского государственного технического университета*, 2012;3(12-1):51–56.
6. Васильченко В.А., Бурковский В.Л. Анализ и выбор структуры объектно-реляционной СУБД медицинской информационной системы. *Вестник воронежского государственного технического университета*, 2015;3(3):57–59.
7. Васильченко В.А., Бурковский В.Л. Структура экспертной системы оперативной диагностики и лечения заболеваний легких. *Вестник воронежского государственного технического университета*, 2016;12(1):28–31.
8. Гончарова Ю.М., Пьяников А.Е, Бурковский В.Л. Нейросетевое моделирование острого пиелонифрита в эксперименте. *Вестник воронежского государственного технического университета*. 2012;8(7-1):54–57.
9. Васильченко В.А., Бурковский В.Л., Данилов А.Д. Алгоритмизация процесса распознавания состояний физиологических объектов на основе специальных рентгеновских изображений. *Компьютерная оптика*. 2019;41(2):296–303.

REFERENCES

1. Belikova T.P. *Modelirovaniye lineynykh fil'trov dlya obrabotki rentgenovskikh izobrazheniy v zadachakh meditsinskoj diagnostiki. Tsifrovaya optika. Obrabotka izobrazheniy i poley v eksperimental'nykh issledovaniyakh*. М.: Nauka, 1990. (In Russ)
2. Gonsales R. *Tsifrovaya obrabotka izobrazheniy*: per. s angl. R. Gonsales, R. Vuds. – М.: Tekhnosfera, 2005. (In Russ)
3. Trufanov G.Ye., Ryazanov V.V., Dergunova N.I. i dr. *Sovmeshchennaya pozitronno-emissonnaya i komp'yuternaya tomografiya (PET-KT) v onkologii*. Elbi–sPb, 2005. (In Russ)
4. Deng, Jia, Dong, Wei, Socher, Richard, Li, Li–Jia, Li, Kai, and Fei–Fei, Li. Imagenet: A large–scale hierarchical image database. *In Computer Vision and Pattern Recognition*, 2009;248–255.
5. Mistyukov B.V., Burkovskiy V.L. Neyrosetevoye modelirovaniye dinamiki nelineynykh sistem. *Vestnik voronezhskogo gosudarstvennogo tekhnicheskogo universiteta*, 2012;3(12-1):51–56. (In Russ)
6. Vasil'chenko V.A., Burkovskiy V.L. Analiz i vybor struktury ob"yektno-relyatsionnoy SUBD meditsinskoj informatsionnoy sistemy. *Vestnik voronezhskogo gosudarstvennogo tekhnicheskogo universiteta*, 2015;3(3):57–59. (In Russ)
7. Vasilchenko V.A., Burkovskiy V.L. Struktura ekspertnoy sistemy operativnoy diagnostiki i lecheniya zabolevaniy legkikh. *Vestnik voronezhskogo gosudarstvennogo tekhnicheskogo universiteta*, 2016;12 (1):28–31. (In Russ)
8. Goncharova YU.M., P'yanikov A.Ye, Burkovskiy V.L. Neyrosetevoye modelirovaniye ostromo piyelonifrita v eksperimente. *Vestnik voronezhskogo gosudarstvennogo tekhnicheskogo universiteta*. 2012;8(7-1):54–57. (In Russ)
9. Vasilchenko VA, Burkovskiy VL, Danilov AD. Algorithmization of the process of recognition of states of living objects based on special x-ray images. *Computer Optics* 2019; 43(2): 296–303. DOI: 10.18287/2412-6179-2017-43-2-296-303.

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Васильченко Владислав Алексеевич, аспирант кафедры электропривода, автоматики и управления в технических системах ФГБОУ ВО «Воронежского государственного технического университета», Воронеж, Российская Федерация
e-mail: v.a.vasilchenko@gmail.com
ORCID: [0000-0002-0626-3384](https://orcid.org/0000-0002-0626-3384)

Vladislav V. Vasilchenko, P. G. of The Department of electric drive, automation and control in technical systems of FSBE of HE "Voronezh State Technical University", Voronezh, Russian Federation

Бурковский Виктор Леонидович, д.т.н., профессор кафедры электропривода, автоматики и управления в технических системах ФГБОУ ВО «Воронежского государственного технического университета», Воронеж, Российская Федерация
e-mail: bvl@vorstu.ru
ORCID: [0000-0001-7957-9681](https://orcid.org/0000-0001-7957-9681)

Viktor L. Burkovsky, Doctor of Technical Sciences, Professor of The Department of electric drive, automation and control in technical systems of FSBE of HE "Voronezh State Technical University", Voronezh, Russian Federation.