



<http://dx.doi.org/10.35596/1729-7648-2025-23-1-60-67>

Оригинальная статья  
Original paper

УДК 004.8.032.26

## МЕТОДИКА ИССЛЕДОВАНИЯ НЕЙРОСЕТЕВЫХ ДЕСКРИПТОРОВ ПРИ РЕШЕНИИ ЗАДАЧИ ПОИСКА АНАТОМИЧЕСКИХ СЛОЕВ НА ИЗОБРАЖЕНИЯХ КОМПЬЮТЕРНОЙ ТОМОГРАФИИ ЛЁГКИХ

А. А. КОСАРЕВА

*Белорусский государственный университет информатики и радиоэлектроники, Объединенный институт проблем информатики Национальной академии наук Беларуси (г. Минск, Республика Беларусь)*

© Белорусский государственный университет информатики и радиоэлектроники, 2025  
Belarusian State University of Informatics and Radioelectronics, 2025

**Аннотация.** Поиск анатомических слоев на изображениях компьютерной томографии лёгких позволит упростить задачу диагностирования и планирования лечения, а также автоматизирует процесс разметки изображений при подготовке обучающей выборки. В статье предлагаются методика сравнения нейросетевых дескрипторов и выбор оптимального нейросетевого метода поиска схожих анатомических областей, гибридный алгоритм поиска, основанный на совместном использовании традиционных и нейросетевых дескрипторов. Такой алгоритм позволил улучшить результат нейросетевого поиска анатомических паттернов, выраженный в миллиметрах до искомого слоя, на 47 % для первых десяти найденных изображений класса сердца и на 18 % – для изображений с позициями от 10 до 100. Итоговый результат поиска анатомической области улучшился по сравнению с традиционными подходами на 9,7 % для найденных изображений с позициями от 10 до 100 и на 2 % – для первых десяти найденных изображений.

**Ключевые слова:** матрицы совместной встречаемости, нейросетевые дескрипторы, глубокое обучение, сверточные нейронные сети, изображения компьютерной томографии.

**Благодарность.** Работа выполнена при поддержке Белорусского республиканского фонда фундаментальных исследований (проект № Ф22КИТГ-001). Автор выражает благодарность и глубокую признательность кандидату технических наук, доценту Василию Алексеевичу Ковалеву и кандидату технических наук, доценту Павлу Викторовичу Камлачу за ценные рекомендации и замечания в процессе работы над статьей.

**Для цитирования.** Косарева, А. А. Методика исследования нейросетевых дескрипторов при решении задачи поиска анатомических слоев на изображениях компьютерной томографии лёгких / А. А. Косарева // Доклады БГУИР. 2025. Т. 23, № 1. С. 60–67. <http://dx.doi.org/10.35596/1729-7648-2025-23-1-60-67>.

## METHODOLOGY FOR STUDYING NEURAL NETWORK DESCRIPTORS IN SOLVING THE PROBLEM OF FINDING ANATOMICAL LAYERS IN COMPUTED TOMOGRAPHY IMAGES OF THE LUNGS

ALEKSANDRA A. KOSAREVA

*Belarusian State University of Informatics and Radioelectronics, United Institute of Informatics Problems of the National Academy of Sciences of Belarus (Minsk, Republic of Belarus)*

**Abstract.** The search for anatomical layers in lung CT images will simplify the task of diagnosis and treatment planning, as well as automate the process of image partitioning when preparing a training sample. The paper proposes a methodology for comparison of neural network descriptors and selection of an optimal neural network

method for searching for similar anatomical regions. Neural network approaches are compared with traditional methods and a hybrid search algorithm based on the joint use of traditional and neural network methods is proposed. Using the proposed algorithm, the neural network search result for anatomical patterns, expressed in mm to the searched layer, was improved by 47 % for the first ten heart-class images found and by 18 % for images with positions from 10 to 100. The final anatomical region search result was improved over using traditional approaches by 9.7 % for retrieved images with positions from 10 to 100 and by 2 % for the first ten retrieved images.

**Keywords:** co-occurrence matrices, neural network descriptors, deep learning, convolutional neural networks, computed tomography images.

**Gratitude.** This work was sponsored by the Belarusian Republican Foundation for Fundamental Research (project No F22KITG-001). The author expresses the gratitude to the Cand. of Sci., Associate Professor Vassili Alekseevich Kovalev and Cand. of Sci., Associate Professor Pavel Viktorovich Kamlach for valuable advice and comments when working on the article.

**For citation.** Kosareva A. A. (2025) Methodology for Studying Neural Network Descriptors in Solving the Problem of Finding Anatomical Layers in Computed Tomography Images of the Lungs. *Doklady BGUIR*. 23 (1), 60–67. <http://dx.doi.org/10.35596/1729-7648-2025-23-1-60-67> (in Russian).

## Введение

Система поиска анатомических областей слоев изображений компьютерной томографии в первую очередь необходима для оптимизации процесса планирования лечения. Второе направление использования подобной системы – автоматизация процесса разметки изображений. Разметка набора данных согласно выбранным признакам – важный этап разработки интеллектуальных медицинских систем. Процесс разметки изображений сложен, субъективен [1] и сильно влияет на результат обучения нейронных сетей. Правильно выбранные и размеченные данные позволяют точно описать границы класса в пространстве признаков при решении задачи классификации. Автоматизация данного процесса дает возможность минимизировать случайные погрешности неверной классификации изображения, сократить временные затраты медицинского специалиста.

Для реализации системы поиска похожих анатомических слоев исследовались традиционные и нейросетевые методы получения дескрипторов изображений. В [2] описывались результаты апробации традиционных методов извлечения признаков изображений и отмечалось, что наилучший традиционный метод получения дескрипторов изображений – матрицы совместной встречаемости. Целью проводимого в [2] исследования являлся выбор оптимального метода решения задачи поиска анатомических слоев изображений компьютерной томографии лёгких. Для этого были поставлены следующие задачи: разработать методику исследования нейросетевых дескрипторов, определить наилучшую обучаемую нейросетевую модель для дальнейшего ее использования в системе поиска похожих изображений слоев компьютерной томографии лёгких, провести сравнительный анализ результатов экспериментов с помощью традиционных и нейросетевых подходов, выбрать оптимальный метод.

## Материалы и методы

При проведении исследования и обучении различных архитектур нейронных сетей использовались два подготовленных набора данных. Первый включал в себя 414 трехмерных изображений компьютерной томографии [3], второй состоял из изображений 144 пациентов, составляющих равномерную выборку пациентов каждого пола и возраста в диапазоне от 18 до 90 лет [4]. Оба набора данных были размечены на три класса: верх лёгкого, печень, сердце.

Эффективная классификация медицинских изображений играет важную роль в оказании клинической помощи и лечения. При работе с традиционными способами извлечения признаков изображений лучшие результаты показывали методы, основанные на работе со структурой медицинского изображения. Соответственно были изучены существующие нейросетевые подходы [5–12]. В итоге исследовалось несколько моделей архитектур сверточных нейронных сетей, таких как AlexNet, VGG16, ResNet, MobileNet, BiT, EfficientNet, Xception.

**AlexNet.** Восьмислойная сверточная нейронная сеть, впервые проявившая себя в 2012 г., выиграв конкурс ImageNet Large Scale Visual Recognition Challenge 2012 с большим отрывом. Эта сеть показала, что функции, полученные в результате обучения, могут превзойти функции, разработанные вручную, тем самым нарушив предыдущую парадигму компьютерного зрения. Особенности архитектуры AlexNet [7]:

- увеличенное окно свертки первого слоя, позволяющее захватывать большие объекты на изображениях;
- уменьшение размеров скрытого слоя путем объединения выходов кластеров нейронов на предыдущем слое в один нейрон на следующем слое на первом, втором и пятом слоях;
- применение простой функции активации ReLu;
- наличие dropout-слоя для контроля обучения.

**VGG16.** Данный класс был предложен исследователями К. Simonyan и А. Zisserman из Оксфордского университета в [8]. Эта нейронная сеть является улучшенной версией AlexNet. Основное отличие архитектур заключается в том, что окна свертки больших размеров (для первого и второго слоев) заменены на несколько фильтров размерами 3×3, следующих один за другим.

**ResNet.** Основной идеей разработки моделей нейронных сетей этого класса являлась попытка решить проблему снижения точности обучения нейронной сети при увеличении глубины ее архитектуры. Для этого было введено понятие «соединение быстрого доступа», позволяющее преобразовывать сеть в ее остаточную версию [10].

**MobileNet.** Особенность ее архитектуры – отсутствие слоев, понижающих размерность. Вместо них для снижения пространственной размерности используется свертка с параметром stride, равным 2. Двумя гиперпараметрами архитектуры MobileNet являются множители ширины и глубины. Множитель ширины отвечает за количество каналов в каждом слое, а глубины – за пространственные размеры входных тензоров. Варьируя эти параметры, можно менять скорость и глубину обучения [11].

**BiT** представляет собой предварительно хорошо обученную на широком наборе данных модель для последующего дообучения, направленного на решение точечных проблем и задач. Такой подход позволяет упростить алгоритм настройки параметров обучения [12].

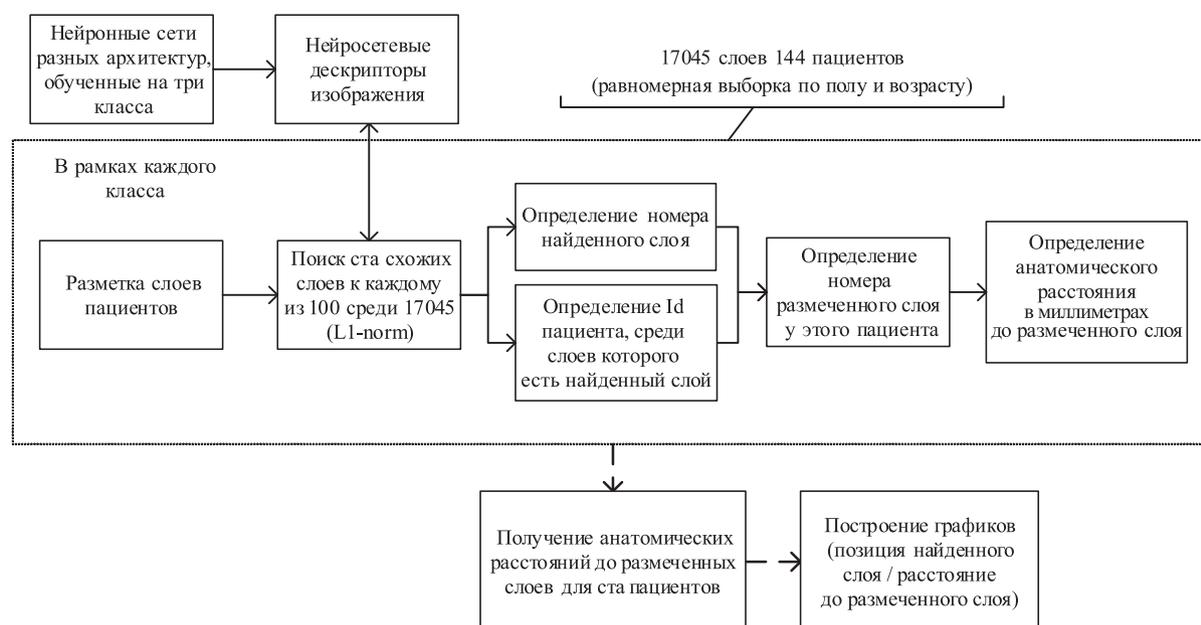
**EfficientNet.** Модели этого класса были разработаны в ходе исследования нового метода масштабирования нейронных сетей [4]. Масштабирование сети может происходить по трем направлениям: преобразование глубины, ширины и разрешения. Каждый из этих параметров влияет на точность работы обученной сети.

**Xception** совмещает в себе два подхода: предложенный алгоритм конкатенирования сверточных ядер разного размера и снижение общего числа весов за счет свертки каналов изображения по отдельности (глубинная пространственная свертка) [13].

Для апробации нейросетевых методов на существующем массиве изображений были обучены следующие нейросетевые модели: ResNet50, ResNet101, ResNet152, ResNet50V2, ResNet101V2, ResNet152V2, Xception, BiT-s, VGG19, AlexNet, MobileNet, MobileNetV2 и все модели класса EfficientNet. Программная реализация процесса обучения нейронных сетей основывалась на использовании открытой библиотеки Keras на языке программирования Python.

Обучение нейронных сетей было направлено на решение задачи классификации слоев КТ-изображений на три выделенных класса: печень, сердце и верх лёгкого. На основе полученных в ходе обучения моделей создавались компоненты извлечения признаков (экстракторы), позволяющие вычислить нейросетевые дескрипторы проходящих через них слоев. Для этого обученные модели нейронных сетей были искусственно лишены выходного слоя, а значение на выходе бралось с предыдущего полносвязного слоя. В результате получены модели-экстракторы, с помощью которых проводился эксперимент с поиском анатомических структур на слоях КТ-изображений. «Схожесть» анатомических паттернов оценивалась по расстоянию в миллиметрах между искомым, размеченным согласно признаку, слоем (144 слоя для каждого класса) и найденным. Определялись сто ближайших найденных слоев к каждому из размеченных.

Для предлагаемой методики структурная схема сравнения нейросетевых дескрипторов слоев изображений компьютерной томографии лёгких представлена на рис. 1.



**Рис. 1.** Структурная схема сравнения нейросетевых дескрипторов слоев изображений компьютерной томографии лёгких  
**Fig. 1.** Structural diagram of comparison of neural network descriptors of lung computed tomography image layers

### Результаты исследований и их обсуждение

Часть нейросетевых моделей, показавших низкие значения точности классификации при обучении (менее 75 %), была отсеяна. В эту категорию попали AlexNet, MobileNet и MobileNetV2. Среди моделей класса EfficientNet была выбрана версия EfficientNetB0, так как она показала лучшее соотношение между качеством обучения и размером памяти, занимаемым обученной моделью [14].

Результаты эксперимента, проведенного согласно структурной схеме на рис. 1, представлены в табл. 1. Оценивалось среднее значение анатомического расстояния в миллиметрах от найденного слоя в пациенте до искомого для десяти первых найденных ближайших (столбец *a*) и для остальных (столбец *b*, позиции 10–100) слоев.

**Таблица 1.** Результаты эксперимента поиска схожих анатомических слоев по трем классам с использованием нейросетевых моделей

**Table 1.** Results of the experiment of searching for similar anatomical layers in three classes using neural network models

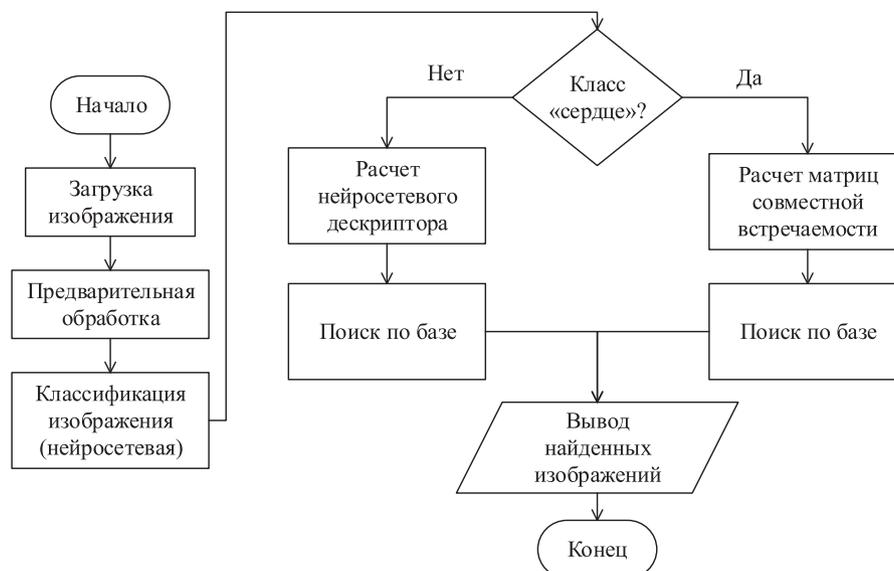
Модель класса	Анатомическое расстояние слоев, мм, для классов						Среднее по модели, мм
	Печень		Верх лёгкого		Сердце		
	<i>a</i>	<i>b</i>	<i>a</i>	<i>b</i>	<i>a</i>	<i>b</i>	
ResNet50	16,18	19,41	3,502	4,17	19,10	31,04	15,57
ResNet101	6,50	9,32	5,50	54,00	25,07	33,31	22,28
ResNet152	4,60	7,56	9,02	9,61	34,94	43,86	18,27
ResNet50V2	3,50	6,20	7,66	9,54	18,25	28,65	12,30
ResNet101V2	8,70	8,43	10,68	11,17	20,98	34,84	15,80
ResNet152V2	5,50	8,13	9,62	12,29	18,25	28,65	13,74
EfficientNetB0	31,00	32,72	16,02	18,69	45,93	51,28	32,61
Xception	3,40	7,98	7,85	9,71	15,11	25,44	11,58
VGG19	5,40	11,13	9,09	12,13	16,74	31,30	14,30
BiT-s	5,20	10,09	6,97	10,20	10,41	21,06	10,66
Среднее по классу	9,62	12,55	8,67	15,76	23,30	33,78	

Согласно табл. 1, суммарно по всем классам лучший результат – у обученной модели ViT-s. При этом Xception находится на втором месте, показывая лучший результат при поиске схожих анатомических структур в области печени и верха лёгкого, но худший в области сердца. Результаты поиска слоя с размеченным признаком «сердце» оказались наихудшими среди выделенных анатомических классов. Это объясняется текстурной «похожестью» слоев, содержащих данный признак. При этом можно выдвинуть гипотезу о том, что классификация с использованием нейросетевых методов позволит скорректировать результат поиска анатомического слоя в области сердца с применением матриц совместной встречаемости.

Выбранные экспериментально нейронные сети ViT-s и Xception позволяют реализовать систему поиска схожего анатомического участка на изображениях компьютерной томографии лёгких. Исходя из полученных результатов, следует обратить внимание на:

- выбор динамического диапазона изображения при обучении и поиске;
- совмещение традиционных и нейросетевых подходов для улучшения результатов поиска, так как это способно повысить качество работы разрабатываемого приложения.

На рис. 2 представлен итоговый гибридный алгоритм поиска анатомических паттернов среди базы изображений. При этом в качестве модели-классификатора необходимо использовать обученные на три класса нейронные сети ViT-s или Xception. Это позволит достичь наилучшего результата при поиске анатомических паттернов (табл. 1). В качестве традиционного метода, корректирующего работу нейронной сети при подсчете дескрипторов изображений, отнесенных к классу «сердце», предлагается использовать алгоритм расчета матриц совместной встречаемости.



**Рис. 2.** Алгоритм поиска анатомических паттернов среди базы изображений  
**Fig. 2.** Algorithm for searching anatomical patterns among the image database

В табл. 2 приведены результаты эксперимента поиска схожих анатомических слоев по трем классам с использованием нейросетевой модели ViT-S и гибридного алгоритма. Оценка проводилась по расстоянию, выраженному в миллиметрах, для найденных первых десяти (столбец *a*) и для позиций от 10 до 100 (столбец *b*) слоев.

**Таблица 2.** Расстояние до найденных схожих анатомических слоев среди слоев изображений компьютерной томографии 100 пациентов

**Table 2.** Distance in mm to found similar anatomical layers among the layers of CT images of 100 patients

Алгоритм	Расстояние до найденных анатомических слоев, мм	
	Для 10 первых	Для 10–100
	<i>a</i>	<i>b</i>
ViT-S	10,41	21,06
ViT-S + GLCM	5,50	17,28
GLCM	5,61	19,13

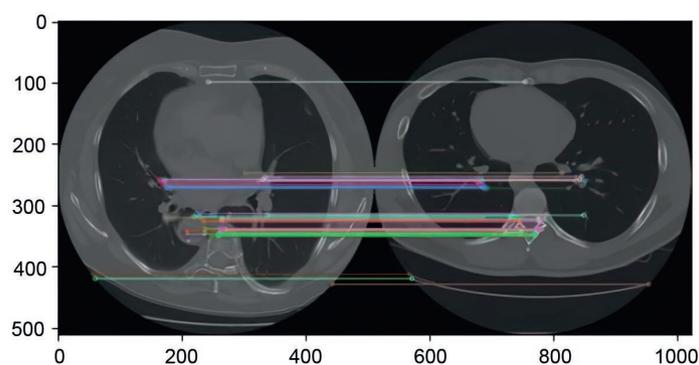
Совмещение традиционных и нейросетевых подходов согласно предлагаемому алгоритму позволило улучшить результат нейросетевого поиска анатомических паттернов, выраженный в миллиметрах до искомого слоя, на 47 % для первых десяти найденных изображений класса «сердце» и на 18 % – для изображений с позициями от 10 до 100. Итоговый результат поиска анатомической области был улучшен по сравнению с использованием традиционных подходов на 9,7 % для найденных изображений с позициями от 10 до 100 и на 2 % – для первых десяти найденных изображений.

В качестве альтернативного традиционного подхода дополнительно рассматривался алгоритм ORB. Согласно проведенным ранее исследованиям, ORB показывал лучший результат среди традиционных подходов при поиске схожих слоев класса «сердце» двух пациентов (табл. 3). При этом для классов «верх лёгкого» и «печень» данный алгоритм продемонстрировал неутешительный результат (отклонение 80 и 69 мм соответственно).

**Таблица 3.** Расстояние между искомым и найденным слоем класса «сердце» для двух пациентов  
**Table 3.** Distance between the desired and found layer of the class “heart” for two patients

Алгоритм	ORB	SIFT	LBP	GLCM
Расстояние, мм	12,5	72,5	95,0	95,0

Дополнительно алгоритм ORB был апробирован на большом количестве изображений. Однако, несмотря на предположение о том, что применение данного алгоритма способно улучшить качество поиска схожих анатомических слоев компьютерной томографии в области сердца, результаты оказались неутешительными. Возник ряд грубых ошибок, доказывающих чувствительность ORB к размерам объектов на изображениях и наличию дополнительных элементов. На рис. 3 изображен пример ложно найденных соотношений между двумя слоями изображений компьютерной томографии класса «сердце». Ошибки включали в себя соотношение границ тела пациента на изображении с границами оборудования для получения изображений компьютерной томографии, а также соотношение лёгочных изменений с сосудистым рисунком, что критично при решении поставленной задачи. Таким образом, доказана невозможность использования ORB-алгоритма в разрабатываемой системе поиска схожих анатомических областей.



**Рис. 3.** Пример ошибки соотношения ключевых точек при работе с ORB-дескрипторами  
**Fig. 3.** Example of key point matching error when working with ORB descriptors

### Заключение

1. Предложен гибридный алгоритм поиска схожих слоев изображений компьютерной томографии, основанный на использовании нейросетевой модели в качестве средства извлечения признаков изображения и предварительной классификации с применением модели ViT-s и матриц совместной встречаемости. Предлагаемый гибридный подход позволил улучшить качество поиска по сравнению с рассмотренными традиционными и нейросетевыми моделями.

2. Разработанная на основе предлагаемого алгоритма система поиска схожих анатомических областей способна помочь медицинскому специалисту при диагностировании и планировании лечения. Также эта система может применяться при автоматической разметке медицинских изображений для дальнейшего обучения нейронных сетей решению разных задач.

### Список литературы

1. Willemink, M. J. Preparing Medical Imaging Data for Machine Learning / M. J. Willemink, W. A. Koszek, C. Hardell // *Radiology*. 2020. Vol. 295, No 1. P. 4–15. DOI: 10.1148/radiol.2020192224.
2. Косарева, А. А. Определение схожего анатомического участка на КТ-изображении грудной клетки с использованием традиционных методов выделения признаков изображения / А. А. Косарева, П. В. Камлач, В. А. Ковалев // Доклады БГУИР. 2022. Т. 20, № 5. С. 48–56.
3. MosMedData: Chest CT Scans with COVID-19 Related Findings Dataset / S. P. Morozov [et al.] // *arXiv:2005.06465*.
4. Исследование и подготовка архива КТ-изображений патологий легких для системы автоматического поиска заданного анатомического участка / А. А. Косарева [и др.] // *BIG DATA и анализ высокого уровня: сб. науч. ст. VII Междунар. науч.-практ. конф.*, г. Минск, 19–20 мая 2021 г. Минск: Бестпринт, 2021. С. 253–257.
5. Xiu, Liu. Deep Learning Approaches to Image Texture Analysis in Material Processing / Xiu Liu, Chris Aldrich // *Metals*. 2022. Vol. 12, No 2. <https://doi.org/10.3390/met12020355>.
6. Yadav, S. S. Deep Convolutional Neural Network Based Medical Image Classification for Disease Diagnosis / S. S. Yadav, S. M. Jadhav // *Journal Big Data*. 2019. No 6. <https://doi.org/10.1186/s40537-019-0276-2>.
7. Krizhevsky, A. ImageNet Classification with Deep Convolutional Neural Networks / A. Krizhevsky, I. Sutskever, G. E. Hinton // *Communications of the ACM*. 2017. Vol. 60, No 6. P. 84–90. DOI: 10.1145/3065386.
8. Simonyan, K. Very Deep Convolutional Networks for Large-Scale Image Recognition / K. Simonyan, A. Zisserman // *arXiv:1409.1556*. 2014. Vol. 1.
9. Deep Residual Learning for Image Recognition / He Kaiming [et al.] // *arXiv:1512.03385*. 2015.
10. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications / A. G. Howard [et al.] // *arXiv:1704.04861v1*. 2017.
11. Big Transfer (BiT): General Visual Representation Learning / A. Kolesnikov [et al.] // *arXiv:1912.11370*. 2019.
12. Mingxing Tan. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks / Mingxing Tan, Quoc V. Le // *arXiv:1905.11946*. 2019.
13. Chollet, F. Xception: Deep Learning with Depthwise Separable Convolutions / F. Chollet // *Conference on Computer Vision and Pattern Recognition*. 2017.
14. Поиск схожих анатомических областей на КТ-изображениях легких с использованием сверточных нейронных сетей / А. А. Косарева [и др.] // *BIG DATA и анализ высокого уровня: сб. науч. ст. VIII Междунар. науч.-практ. конф.*, г. Минск, 11–12 мая 2022 г. Минск: Белор. гос. ун-т информ. и радиоэлек., 2022. С. 476–482.

### References

1. Willemink M. J., Koszek W. A., Hardell C., Jie Wu, Fleischmann D., Harvey H., et al. (2020) Preparing Medical Imaging Data for Machine Learning. *Radiology*. 295 (1), 4–15. DOI: 10.1148/radiol.2020192224.
2. Kosareva A. A., Kamlach P. V., Kovalev V. A. (2022) Determination of a Similar Anatomical Area on a Chest CT Image Using Traditional Image Feature Extraction Methods. *Doklady BGUIR*. 20 (5), 48–56. <https://doi.org/10.35596/1729-7648-2022-20-5-48-56> (in Russian).
3. Morozov S. P., Andreychenko A. E., Pavlov N. A., Vladzimirskyy A. V., Ledikhova N. V., Gombolevskiy V. A., et al. (2020) MosMedData: Chest CT Scans with COVID-19 Related Findings Dataset. *arXiv:2005.06465*.
4. Kosareva A. A., Snezhko E. V., Kamlach P. V., Kovalev V. A. (2021) Pulmonary Pathologies CT Images Archive's Research and Preparation for a Given Anatomic Area Automatic System. *BIG DATA and Advanced Analytics, Collection of Scientific Articles of the VII International Scientific and Practical Conference, Minsk, 19–20 May*. Minsk, Bestprint Publ. 253–257 (in Russian).
5. Xiu Liu, Chris Aldrich (2022) Deep Learning Approaches to Image Texture Analysis in Material Processing. *Metals*. 12 (2). <https://doi.org/10.3390/met12020355>.
6. Yadav S. S., Jadhav S. M. (2019) Deep Convolutional Neural Network Based Medical Image Classification for Disease Diagnosis. *Journal Big Data*. (6). <https://doi.org/10.1186/s40537-019-0276-2>.
7. Krizhevsky A., Sutskever I., Hinton G. E. (2017) ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*. 60 (6), 84–90. DOI: 10.1145/3065386.
8. Simonyan K., Zisserman A. (2014) Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv:1409.1556*. 1.
9. He Kaiming, Zhang Xiangyu, Ren Shaoqing, Sun Jian (2015) Deep Residual Learning for Image Recognition. *arXiv:1512.03385*.
10. Howard A. G., Zhu M., Bo Chen, Kalenichenko D., Wang W., Weyand T. (2017) MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *arXiv:1704.04861v1*.

11. Kolesnikov A., Beyer L., Zhai X., Puigcerver J., Yung J. (2019) Big Transfer (BiT): General Visual Representation Learning. *arXiv:1912.11370*.
12. Mingxing Tan, Quoc V. Le (2019) EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *arXiv:1905.11946*.
13. Chollet F. (2017) Xception: Deep Learning with Depthwise Separable Convolutions. *Conference on Computer Vision and Pattern Recognition*.
14. Kosareva A. A., Kamlach P. V., Kovalev V. A., Snezhko E. V., Radzhabov A. G. (2022) Search for Similar Anatomical Areas on CT Images of Lungs Using Convolutional Neural Networks. *BIG DATA and Advanced Analytics, Collection of Scientific Articles of the VIII International Scientific and Practical Conference, Minsk, 11–12 May 2022*. Minsk, Belarusian State University of Informatics and Radioelectronics. 476–482 (in Russian).

#### Сведения об авторе

**Косарева А. А.**, ассист. каф. электронной техники и технологии, Белорусский государственный университет информатики и радиоэлектроники; мл. науч. сотр. Объединенного института проблем информатики Национальной академии наук Беларуси

#### Адрес для корреспонденции

220013, Республика Беларусь,  
г. Минск, ул. П. Бровки, 6  
Белорусский государственный университет  
информатики и радиоэлектроники  
Тел.: +375 17 293-88-60  
E-mail: kosareva@bsuir.by  
Косарева Александра Андреевна

#### Information about the author

**Kosareva A. A.**, Assistant at the Electronic Engineering and Technology Department, Belarusian State University of Informatics and Radioelectronics; Junior Researcher at the United Institute of Informatics Problems of the National Academy of Sciences of Belarus

#### Address for correspondence

220013, Republic of Belarus,  
Minsk, P. Brovki St., 6  
Belarusian State University  
of Informatics and Radioelectronics  
Tel.: +375 17 293-88-60  
E-mail: kosareva@bsuir.by  
Kosareva Aleksandra Andreevna