

СМАЛЮК А.Ф.¹, ДЕШКО М.С.¹, КУПЧИКОВА И.Д.²

СЕГМЕНТАЦИЯ ДЕРМАТОСКОПИЧЕСКИХ ИЗОБРАЖЕНИЙ НОВООБРАЗОВАНИЙ КОЖИ. СРАВНЕНИЕ МЕТОДИК

¹Белорусский национальный технический университет

²Институт бизнеса Белорусского государственного университета
г. Минск, Республика Беларусь

В работе рассмотрен ряд методик сегментации дерматоскопических изображений новообразований кожи для выявления областей, занимаемых данными новообразованиями. Выполнение сегментации необходимо как первый этап большинства методик компьютерной диагностики злокачественности новообразований. Ряд методик, таких как ABCDE, используют форму новообразования как один из критериев постановки диагноза, для других, таких как использование сверточных нейронных сетей, выделение новообразования позволяет повысить точность получаемых результатов. В работе рассмотрены три способа сегментации: пороговая обработка с использованием метода Оцу для вычисления величины порога, сверточная нейронная сеть, построенная по архитектуре U-net, и аналогичная сверточная нейронная сеть с добавленным механизмом внимания. Рассмотрены достоинства и недостатки каждой из методик, а также возможности совместного их применения для получения наилучших результатов сегментации.

Ключевые слова: меланома, новообразование кожи, дерматоскоп, сегментация, метод Оцу, пороговая обработка, сверточная нейронная сеть, механизм внимания

Введение

Меланома кожи является опасным онкологическим заболеванием, с достаточно высоким показателем смертности (27%), причем заболеваемость меланомой кожи в Беларуси показывает существенный рост (более чем в 3 раза за 25 лет) [1]. Кроме того, достаточно высока доля лиц, болеющих ею в трудоспособном возрасте. В связи с этим, важным вопросом является ранняя диагностика меланомы кожи, необходимая для ее успешного лечения.

Самая распространенная на сегодняшний день методика диагностики ABCDE и ей подобные [2, 3] не всегда позволяют распознать злокачественность новообразования на ранних стадиях его развития, особенно, если новообразование имеет небольшой размер. И, зачастую, для постановки правильного диагноза врач должен иметь большой опыт и высокую квалификацию.

В связи с этим, особую важность получают методики компьютерной диагностики, которые могут приближаться по точности получаемых диагнозов к лучшим врачам-онкологам. Данные системы могут использовать методики, основанные на критериях, таких как, однородность цвета, форма и размер новообразования, наличие определенных структур [4], либо использовать технологии нейронных сетей.

И в случае анализа критериев, и в случае использования нейронных сетей важной задачей является сегментация изображения, для выявления в нем области, занимаемой новообразованием. На

основе результатов сегментации делаются выводы об особенностях формы новообразования. При использовании нейронных сетей сегментация не является строго обязательной, но в ряде работ было показано, что при использовании для обучения изображений, в которых наложена маска, закрывающая все кроме самого новообразования, точность получаемого результата может увеличиваться на 10-20%.

Сегментация с использованием пороговой обработки изображения

В случае меланомы, в большинстве случаев цвет новообразования отличается от цвета окружающей здоровой кожи. Это позволяет использовать для сегментации пороговую обработку изображения. Результатом такой обработки является двухцветное изображение, на котором область занимаемая новообразованием выделена одним цветом, а окружающая здоровая кожа – другим. Эта методика не требует больших вычислительных мощностей, и позволяет быстро получить результат на не самом дорогостоящем оборудовании. Проблемой для данной методики является правильный выбор величины порога. Так как цвет кожи у пациентов может существенно отличаться (особенно если выполняется обработка изображений из международных баз), могут отличаться условия, в которых сделан снимок и оборудование, используемое для него. Как следствие, каждое изображение должно иметь собственную величину порога для корректной сегментации.

Для небольших баз изображений этот порог может подбираться вручную для каждого изображения, но современные базы для обучения нейронных сетей могут содержать десятки тысяч изображений, что делает ручной подбор порогов слишком трудоемким. Существуют ряд методов автоматического подбора порога на основе гистограммы изображения. Одним из самых популярных является метод Оцу [5]. Данный метод позволяет подобрать порог таким образом, чтобы внутриклассовая дисперсия (1) в двух классах пикселей, на которые делится изображение, была минимальной.

$$\sigma^2 \omega(t) = \omega_1(t) \sigma_1^2(t) + \omega_2(t) \sigma_2^2(t). \quad (1)$$

Здесь ω_i вероятности классов, σ_2^2 – дисперсии этих классов.

Было показано, что минимизация дисперсии внутри классов равнозначна максимизации дисперсии между классами (2).

$$\sigma_b^2(t) = \sigma^2 - \sigma^2 w(t) = \omega_1(t) \omega_2(t) [\mu_1(t) - \mu_2(t)]^2. \quad (2)$$

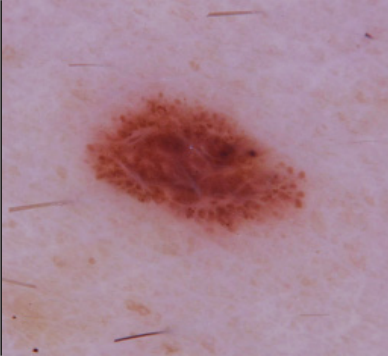

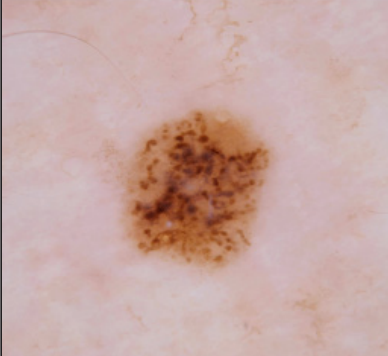
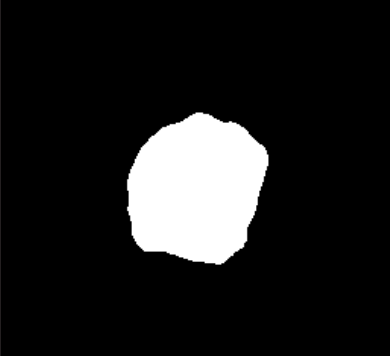
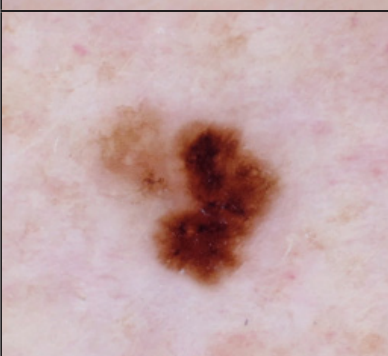

Здесь $\mu_1(t)$ – среднее арифметическое класса.

Алгоритм вычисления порога заключается в преобразовании изображения в оттенки серого, построении гистограммы изображения, и перебора всех величин порога, для каждой из которых вычисляется дисперсия между классами, порог с наибольшей дисперсией и будет результатом.

Данный алгоритм был реализован авторами на платформе Java [6], примеры полученной сегментации для дерматоскопических изображений показаны в таблице 1.

Таблица 1

Примеры сегментации дерматоскопических изображений пороговой обработкой по методу Оцу

Исходное изображение	Сегментация
	
	
	


Несмотря на то, что применение пороговой обработки с использованием порога, полученного по методу Оцу, позволяет выполнить сегментацию с хорошим качеством для значительной части дерматоскопических изображений он, как и другие пороговые методы, имеет существенные недостатки при обработке изображений меланомы кожи.

Заметная часть меланом может иметь зоны пониженной пигментации, которые не сильно отличаются по уровню яркости от окружающей кожи, или даже светлее ее. Общим недостатком пороговых

методов является то, что данные зоны сегментируются не как часть новообразования, а как часть фона, то есть окружающей кожи. Кроме того, снимки, полученные на некоторых видах оборудования, имеют относительно низкую яркость в периферийных областях снимка, в этом случае данные области могут выделяться как часть новообразования, особенно, если у самого новообразования невысокая пигментация или оно имеет небольшой размер. Примеры таких новообразований и их ошибочной сегментации показаны в таблице 2.

Таблица 2

Примеры некорректной сегментации меланомы кожи



Подобные погрешности могут вызывать проблемы у систем получения диагноза. Так использование сегментации пороговой обработкой без внесения дополнительных корректив для создания обучающих наборов изображений для нейронных сетей, исполь-

зуемых для классификации изображений, не повысило точность результатов из-за значительного количества ошибок в сегментации.

Несмотря на это, сегментация с помощью пороговой обработки не является полностью

беспольной. Получаемые с ее помощью результаты могут использоваться для составления обучающих наборов изображений для сверточных нейронных сетей, выполняющих сегментацию, если в часть полученных масок внести исправления. Так, для обучения сверточных нейронных сетей, рассматриваемых далее, обучающие наборы были составлены из результатов пороговой обработки изображений с использованием метода Оцу. Была взята часть изображений, которые изначально были сегментированы правильно, и часть изображений, для которых пришлось сделать некоторые корректировки вручную, например, закрасив неправильно сегментированные области внутри новообразований, или закрасив фоновым цветом периферийные области.

Сегментация с помощью сверточной нейронной сети архитектуры U-net

Архитектура U-net и различные ее вариации являются одними из самых распространенных архитектур сверточных сетей, применяемых для семантической сегментации изображений.

Сети, использующие архитектуру U-net, являются чисто сверточными сетями, не содержащими полносвязных слоев.

Впервые данная архитектура была предложена в 2015 году Роненнбергом, Фишером, и Броксом для сегментации клеток на микроскопических снимках [7], и с тех пор получила широкое распространение для самых разных задач сегментации. Ее достоинствами являются достаточно высокая скорость обучения, и способность обучаться на относительно небольших обучающих наборах, включающих сотни изображений.

Сети U-net состоят из двух частей: в первой находятся сверточные слои, которые постепенно понижают разрешение изображения, повышая при этом количество каналов, а во второй части происходит обратный процесс, при прохождении через слои количество каналов уменьшается, а размер изображения постепенно увеличивается до исходного.

Детали структуры нейронной сети могут отличаться для каждого конкретного случая, в зависимости от размера исходного изображения, размера итогового изображения.

Структура сети используемой в данной работе показана на рисунке 1.

В первой половине сети каждый уровень состоит из двух сверточных слоев 3×3 без отступов с функцией активации ReLU (изображаются короткими горизонтальными стрелками), после которых следует пулинговый слой 2×2 с шагом 2 (изображаются вертикальными стрелками, направленными вниз), который обеспечивает уменьшение размера изображения. Во второй половине идет обратный процесс, и, как следствие, каждый уровень

начинается с деконволюционного слоя (изображаются вертикальными стрелками, направленными вверх), обеспечивающего увеличение изображения. После него следуют сверточные слои свертки с функцией активации ReLU.




Рисунок 1. Структура сети U-net

Как видно из рисунка 1, кроме последовательных связей между слоями, есть еще дополнительные связи, называемые пропускными соединениями (skip connections), обеспечивающие передачу информации между слоями одного размера в процессе повышения и понижения размера изображения (изображаются серыми горизонтальными стрелками). Данные связи обеспечивают значительно большую скорость обучения, решая проблему исчезающего градиента. Также их наличие уменьшает требования к объему обучающего набора изображений для успешного обучения.

Данная нейронная сеть была реализована авторами на языке Python с использованием библиотек Keras TensorFlow [8]. Количество обучаемых параметров сети: 1941105.

Набор обучающих изображений состоит из 400 исходных изображений размером 256×256 и соответствующих им черно-белых масок. Маски были получены с использованием метода пороговой обработки, около половины их было подвергнуто корректировке вручную. В качестве валидационного набора при обучении автоматически выделяется 10 % исходного обучающего набора.

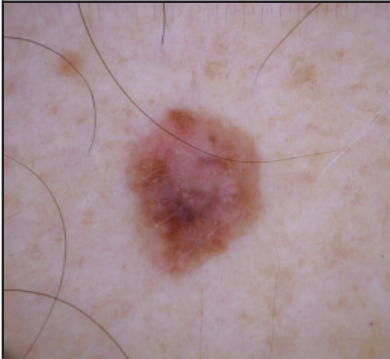
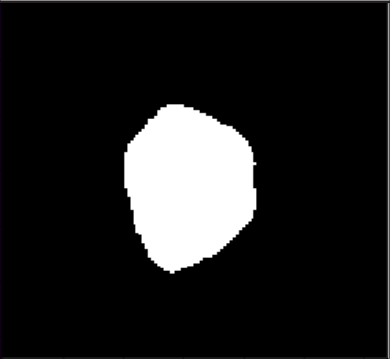
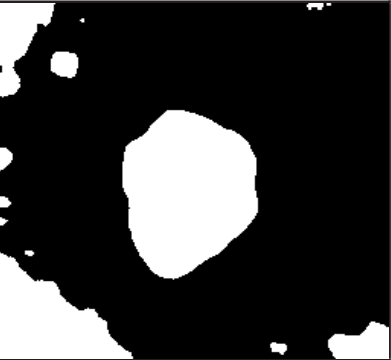

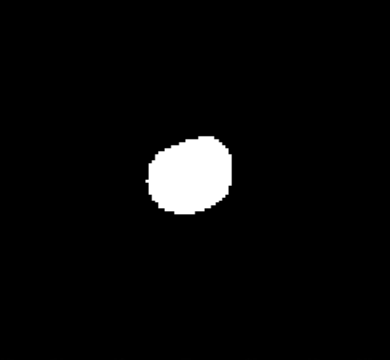

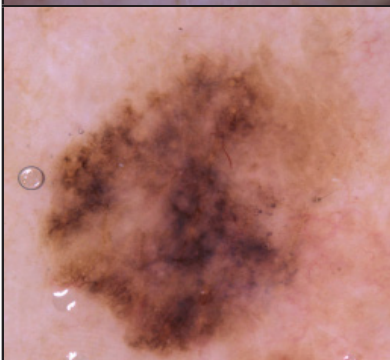
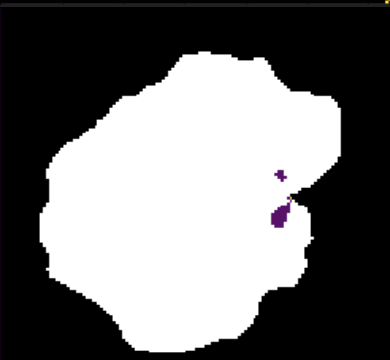
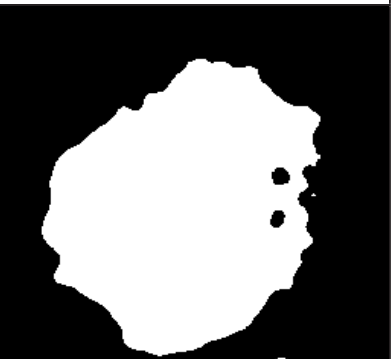
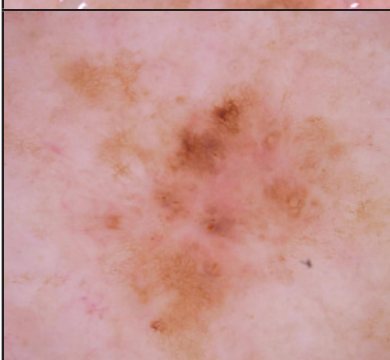


Обучение нейронной сети выполнялось на компьютере с ЦП Apple m1 с использованием встроенных в него средств ускорения для нейронных сетей. Процесс обучения завершился за 39 шагов и занял около 4 минут.

Максимальная точность в валидационном наборе составила 0.9767

Для оценки качества полученных масок, и сравнения их с результатами пороговой обработки методом Оцу был создан отдельный тестовый набор изображений, не использовавшийся при обучении нейронной сети ни в обучающем ни в валидационном наборах. Для изображений из этого набора были получены маски, типичные примеры которых можно увидеть в таблице 3.

Таблица 3

Примеры масок, полученных при обработке изображений из тестового набора и масок полученных методом Оцу

Исходное изображение	Маска, полученная с помощью нейронной сети	Маска, полученная с помощью пороговой обработки
		
		
		
		

Как видно из примеров, в ряде случаев, нейронная сеть демонстрирует значительно лучший результат: реже включает в маску новообразования периферию снимка, и демонстрирует лучшие результаты для новообразований, имеющих относительно невысокую пигментацию.

Сегментация с использованием сверточной сети U-net с механизмом внимания

В 2018 году был предложен новый вариант архитектуры U-net, использующей механизм внимания [9].

Принцип данного механизма заключается в том, что в пропускных соединениях архитектуры,

применяется не простое суммирование сигналов из первой и второй половин сети, а вычисление на основе получаемого с предыдущего уровня сигнала g коэффициентов, которые показывают в каких областях изображения имеется наибольшая вероятность появления искомого класса. Перед суммированием получаемый из первой половины сети сигнал x умножается на данные коэффициенты. Таким образом, должно уменьшаться количество посторонних артефактов, и повышаться качество сегментации.

Изначально данный вариант архитектуры был разработан для анализа снимков печени, поджелудочной железы и почек. Архитектура блока внимания, предложенного авторами [9] показана на рисунке 2.

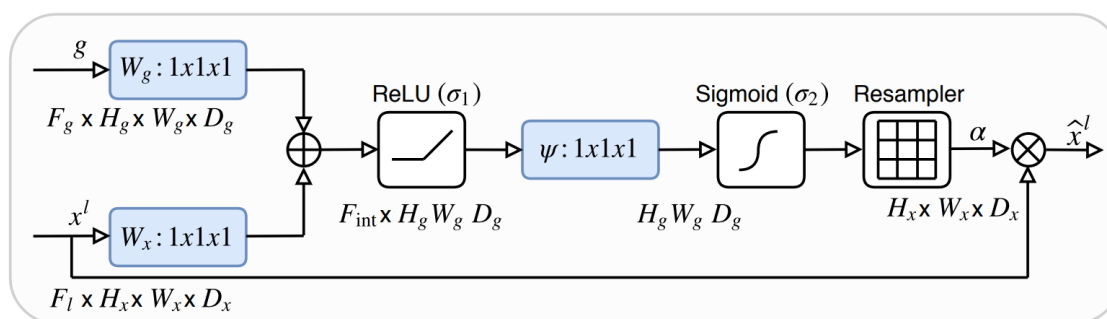


Рисунок 2. Архитектура блока внимания

В данном блоке сначала сигнал из первой половины сети x и сигнал, получаемый с предыдущего уровня g , приводятся к одному размеру и суммируются, затем к ним применяется функция активации ReLU, фильтр $1 \times 1 \times 1$, результатом которого будет массив коэффициентов и сигмоидная функция активации для нормализации коэффициентов. Далее выполняется ресамплинг, чтобы привести массив коэффициентов к нужной размерности. Его результатом будет массив коэффициентов, на который умножается получаемый из первой половины сигнал x , для его дальнейшего использования.

Данная нейронная сеть, имеющая общую структуру аналогичную предыдущей, с добавлением описанных здесь блоков внимания была также реализована на языке Python с использованием библиотек Keras, TensorFlow. Количество обучаемых параметров сети: 2269429.

Для обучения использовался тот же обучающий набор изображений, что и для обычной архитектуры U-net.

Из-за дополнительных вычислений, связанных с получением коэффициентов внимания и несколько большего количества обучаемых параметров сети, время, затрачиваемое на обучение сети оказывается в среднем в 1.5 раза большим.

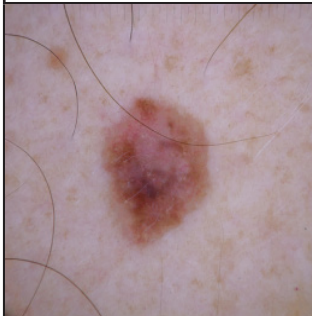
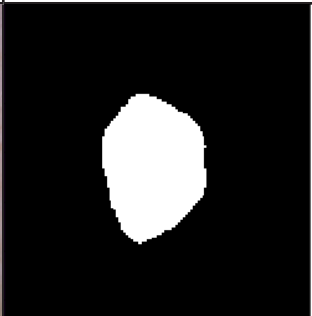

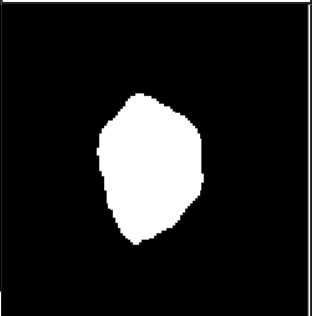

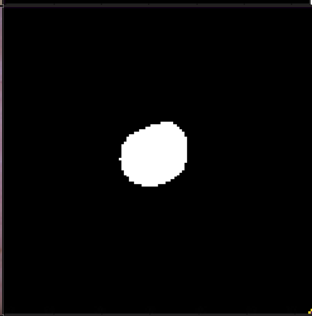
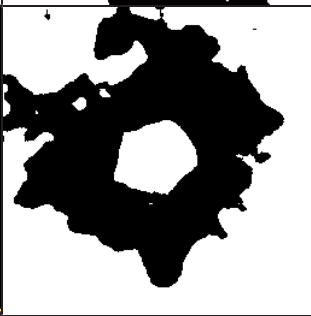
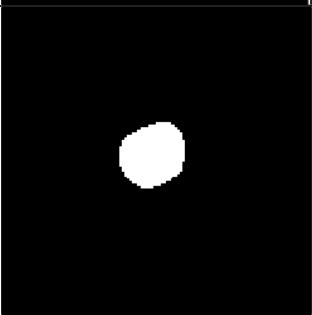
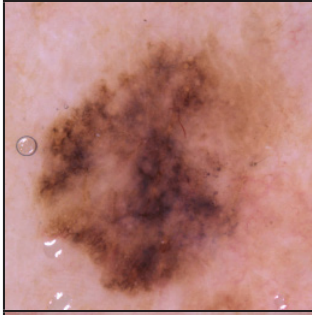

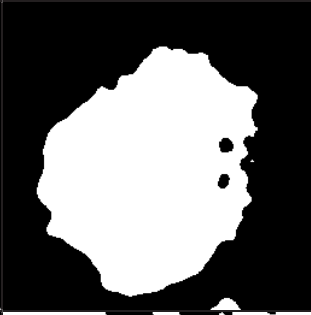
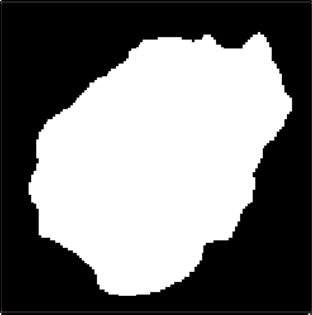
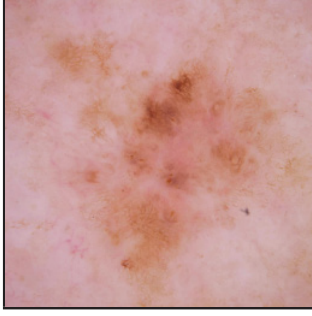



Максимальная точность на валидационном наборе данных 0.9768.

Сравнение масок, полученных из тестового набора дерматоскопических изображений показывает, что данная архитектура дает несколько лучшие результаты, в том, что касается более полного определения новообразований со слабой пигментацией и светлых областей внутри новообразований.

Примеры масок, полученных всеми тремя рассматриваемыми методами показаны в таблице 4.

Таблица 4

Примеры масок, полученных с помощью пороговой обработки, сети архитектуры U-net, и сети архитектуры U-net с механизмом внимания.

Исходное изображение	Маска, полученная с помощью нейронной сети	Маска, полученная с помощью пороговой обработки	Маска, полученная с помощью нейронной сети с механизмом внимания
			
			
			
			

Заключение

В работе рассмотрены три методики сегментации дерматоскопических изображений: с использованием пороговой обработки изображений методом Оцу, с использованием сверточной сети архитектуры U-net, и сверточной сети архитектуры U-net с механизмом внимания.

Метод пороговой обработки оказался наименее требовательным к вычислительным ресурсам, и наиболее простым в реализации, но при этом он демонстрирует наибольшее количество ошибок среди трех рассматриваемых методов, и его результаты не могут использоваться без дополнительной ручной корректировки. При этом часть его результатов,

с небольшими ручными корректировками, могут использоваться для создания обучающих наборов изображений для нейронных сетей архитектуры U-net. Рассмотренные нейронные сети показали значитель-

но лучшие результаты, продемонстрировав большую точность при сегментации. Наименьшее количество явных погрешностей показала сеть U-net с механизмом внимания.

ЛИТЕРАТУРА / REFERENCES

1. Жуковец А.Г., Океанов А.Е., Моисеев П.И., Прокошин А.В. Меланома кожи в Республике Беларусь: эпидемиология, диагностика и результаты лечения // Онкологический журнал. – 2017. – Т. 11, № 1. – С. 35-46.
2. Rigel DS, Russak J, Friedman R. The evolution of melanoma diagnosis: 25 years beyond the ABCDs. CA Cancer J Clin. 2010 Sep-Oct;60(5):301-16.
3. Duarte AF, Sousa-Pinto B, Azevedo LF, Barros AM, Puig S, Malvehy J, Haneke E, Correia O. Clinical ABCDE rule for early melanoma detection. Eur J Dermatol. 2021 Dec 1;31(6):771-778.
4. Mabrouk MS, Sayed AY, Afifi HM, Sheha MA, Sharwy A. Fully Automated Approach for Early Detection of Pigmented Skin Lesion Diagnosis Using ABCD. J Health Inform Res. 2020 Mar 3;4(2):151-173.
5. Core Java: Fundamentals, Volume 1 (Oracle Press Java) / Cay Horstmann. – Oracle Press, 2021. – 944 p.
6. N. Otsu. A threshold selection method from gray-level histograms (англ.) // IEEE Trans. Sys., Man., Cyber.: journal. – 1979. – Vol. 9. – P. 62-66.
7. Ronneberger, Olaf & Fischer, Philipp & Brox, Thomas. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. LNCS. 9351. 234-241.
8. Шолле Франсуа. Глубокое обучение на Python. 2-е межд. издание. - СПб. : Питер, 2023. – 576 с.
9. Oktay, Ozan et al. “Attention U-Net: Learning Where to Look for the Pancreas.” ArXiv abs/1804.03999 (2018): n. pag

SMALIUK A.F.¹, AUSIEVICH A.M.¹, DZESHKA M.S.¹, KUPCHYKAVA I.D.²

SEGMENTATION OF DERMATOSCOPIC IMAGES OF SKIN LESIONS. COMPARISON OF METHODS

¹Belarusian National Technical University

²School of business of Belarusian State University
Minsk, Republic of Belarus

The work discusses a number of techniques for segmenting dermoscopic images of skin lesions to identify the areas occupied by these lesions. Segmentation is necessary as the first stage of most methods of computer diagnostics of malignancy of neoplasms. A number of techniques, such as ABCDE, use the shape of the tumor as one of the criteria for making a diagnosis; for others, such as the use of convolutional neural networks, identifying the tumor allows one to increase the accuracy of the results obtained. The work discusses three methods of segmentation: thresholding using Otsu's method to calculate the threshold value, a convolutional neural network built on the U-net architecture, and a similar convolutional neural network with an added attention mechanism. The advantages and disadvantages of each method are considered, as well as the possibility of using them together to obtain the best segmentation results.

The paper considers the application of an algorithm based on a morphological projector for determining structural differences for comparing dermoscopic images. This will allow to identify changes that have occurred in skin lesions over time, for a more accurate diagnosis of their malignancy. The proposed algorithm makes it possible to detect differences in images even if there is a significant difference in the brightness and color levels of the compared images, and also ignores small insignificant details, such as noise, dermatoscope optics marks, hair, etc. A method for correcting the desynchronization of images using the structural similarity index as a similarity metric, and the sine-cosine algorithm as an optimization algorithm is proposed. The proposed algorithms were tested on dermoscopic images and the possibility of their application was demonstrated.

Keywords: melanoma, skin lesion, dermatoscope, segmentation, Otsu method, thresholding, convolutional neural network, attention mechanism



Смалюк Антон Федорович, кандидат физико-математических наук. Ведущий научный сотрудник научно-исследовательской лаборатории Механики материалов и динамики технических систем Белорусского национального технического университета.

Smalyuk A.F. Phd. Leading Scientist of the Research Laboratory of Mechanics of Materials and Dynamics of Technical Systems of Belarusian National Technical University.

E-mail: dsmsm@bntu.by



Дешко Мария Степановна, магистрант кафедры «Программное обеспечение информационных систем и технологий» Белорусского национального технического университета.

Dzeshka M. S. Master's student of the Department "Software of Information Systems and Technologies" at the Belarusian National Technical University.

E-mail: fitr@bntu.by



Купчикова Ирина Дмитриевна, студент кафедры «Цифровых систем и технологий» Института бизнеса Белорусского государственного университета.

Kupchikava I.D., student of the Department "Digital Systems and Technologies" at School of business of Belarusian State University.

E-mail: irinakupchikova@outlook.com