

Возможности применения нейросетей в оценке результатов внутрисосудистого ультразвукового исследования (обзор литературы)

Мадонов П.Г., Хидирова Л.Д., Ковалёв Е.А.

ФГБОУ ВО «Новосибирский государственный медицинский университет» Минздрава России

Possibilities of neural networks application in assessing the results of intravascular ultrasound (literature review)

Madonov P.G., Khidirova L.D., Kovalev E.A.

Novosibirsk State Medical University

АННОТАЦИЯ

В обзоре рассмотрен опыт применения нейросетей в оценке результатов внутрисосудистых ультразвуковых исследований (выявление нестабильных бляшек, выделение просвета и слоев стенки сосуда, прогнозирование фракционного резерва кровотока).

Ключевые слова: нейросети, машинное обучение, внутрисосудистая визуализация, внутрисосудистое УЗИ.

ABSTRACT

The review considers the experience of neural networks use in assessing the results of intravascular ultrasound investigation (detection of vulnerable plaques, extraction of the lumen and layers of the vessel wall, prediction of the fractional flow reserve).

Keywords: neural networks, machine learning, intravascular imaging, intravascular ultrasound.

ВВЕДЕНИЕ

Искусственные нейросети (ИНС) — это математические модели функционирования традиционных для живых организмов нейросетей, которые представляют собой сети нервных клеток. Как и в биологическом аналоге, в искусственных сетях основным элементом выступают нейроны, соединенные между собой и образующие слои, число которых может быть разным в зависимости от сложности нейросети и ее назначения (решаемых задач). Одна из главных функций нейронных сетей — возможность обучения. Обучение нейронной сети — это процесс, в ходе которого параметры нейронной сети настраиваются по-

INTRODUCTION

Artificial neural networks (ANNs) are mathematical models of the functioning of neural networks traditional for living organisms, which are networks of nerve cells. As in the biological analogue, in artificial networks, the main element is neurons, connected to one another and forming layers, the number of which can be different depending on the complexity of the neural network and its assignment (tasks to be solved). One of the main functions of neural networks is learning capability. Neural network training is a process during which the parameters of a neural network are changed by simulation of the environment in which this network is embedded. It is thanks

Поступила 02.12.2020
Принята 22.01.2021

Автор, ответственный за переписку
Хидирова Людмила Даудовна: ФГБОУ ВО «Новосибирский государственный медицинский университет» Минздрава России. 630091, г. Новосибирск, Красный просп., 52.
E-mail: h_ludmila73@mail.ru

Received 02.12.2020
Accepted 22.01.2021

Corresponding author
Khidirova Lyudmila Daudovna: Novosibirsk State Medical University, 52, Krasny Prospect, Novosibirsk, 630091, Russia.
E-mail: h_ludmila73@mail.ru

средством моделирования среды, в которую эта сеть встроена. Именно благодаря возможности обучения нейросети решаются задачи распознавания образов, классификации, прогнозирования и т.д. Для обучения используются обучающая и тестовая выборки.

Нейросети в медицине сегодня являются активно развивающимся направлением, способным служить хорошим подспорьем для врачей-клиницистов, облегчая выполнение рутинных задач и повышая надежность и точность различных рабочих процессов за счет исключения ошибок, обусловленных человеческим фактором. Первые попытки создания нейросетевых диагностических систем относятся к 40–50-м годам XX в., т.е. сразу после появления основополагающих работ У. Мак-Каллока, У. Питтса, Ф. Розенблатта, заложивших теоретические основы нейросетевых технологий. Однако практическое применение такие системы начали находить только в 80–90-х годах прошлого века. Список областей медицины, в которых стали использоваться нейросетевые технологии, чрезвычайно обширен и продолжает расти, что свидетельствует о перспективности этого научного направления.

В настоящее время в клинической науке и практике формируется новый подход к рассмотрению каждого конкретного случая заболевания, получению информации, необходимой для определения стратегии повышения качества медицинской помощи. Наиболее ярко этот подход реализуется в рамках доказательной медицины (evidence-based medicine) [1]. Целью нового подхода является разработка и применение клинических методов, позволяющих делать достоверные заключения, исключая влияние систематических, случайных и иных ошибок [2], для чего и используются ИНС. Так, на момент написания обзора FDA (Управление по санитарному надзору за качеством пищевых продуктов и медикаментов, США) одобрило к применению в клинической практике 64 нейросети в лучевой диагностике и кардиологии [3–5].

АВТОМАТИЗИРОВАННОЕ ОБНАРУЖЕНИЕ НЕСТАБИЛЬНЫХ БЛЯШЕК НА ИЗОБРАЖЕНИЯХ, ПОЛУЧЕННЫХ ПРИ ВНУТРИСОСУДИСТОМ УЛЬТРАЗВУКОВОМ ИССЛЕДОВАНИИ (ВСУЗИ)

Для стратификации рисков при проведении чрескожного коронарного вмешательства (ЧКВ) перед эндоваскулярным хирургом периодически возникает необходимость проведения оценки стабильности бляшки или морфологической

to the trainability of the neural network that the tasks of pattern recognition, classification, prediction, etc. are solved. For learning, training and test data sets are used.

Neural networks in medicine today are an actively developing research area that can serve as a good help for clinicians, facilitating the execution of routine tasks and increasing the reliability and accuracy of various work processes by eliminating errors caused by the human factor. The first attempts to create neural network diagnostic systems date back to the 40–50s of the 20th century; immediately after the appearance of the fundamental works of W. McCulloch, W. Pitts, F. Rosenblatt, who laid the theoretical foundations of neural network technologies. However, such systems began to find practical application only in the 80–90s of the last century. The list of areas of medicine in which neural network technologies have begun to be used is extremely extensive, and continues to grow, which indicates the prospects of this scientific direction.

Currently, in clinical science and practice, a new approach is being formed to consider each specific case of the disease, to obtain information necessary to determine a strategy for improving the quality of medical care. This approach is most clearly implemented in the framework of evidence-based medicine [1]. The purpose of the new approach is the development and application of clinical methods that allow making reliable conclusions, excluding the influence of systematic, random and other errors [2], for which ANNs is used. Thus, at the time of writing the review, the FDA (Food and Drug Administration, USA) approved 64 neural networks for use in clinical practice in radiology diagnostics and cardiology [3–5].

AUTOMATED DETECTION OF VULNERABLE PLAQUES IN INTRAVASCULAR ULTRASOUND (IVUS) IMAGES

To stratify the risks during percutaneous coronary intervention (PCI) the endovascular surgeon has to periodically assess the stability of the plaque or the morphological structure of atheroma (length of the lesion, presence of calcifications). To assess these two indicators, two methods are currently used: intravascular ultrasound and intravascular optical coherence tomography (OCT). The use of both methods in routine practice is expensive and increases the time of PCI, therefore, the developers of algo-

структуры атеромы (протяженность поражения, наличие кальцинатов). Для оценки этих двух показателей на сегодняшний день применяется два метода — внутрисосудистое ультразвуковое исследование и внутрисосудистая оптическая когерентная томография (ОКТ). Использование в рутинной практике обоих методов является дорогостоящим и увеличивает время проведения ЧКВ, поэтому разработчики алгоритмов, построенных на машинном обучении, предлагают методы, с помощью которых будет возможна оценка по результатам ВСУЗИ не только морфологии атеромы, но и ее стабильности [6].

На сегодняшний день существует два алгоритма автоматического определения нестабильности бляшки по результатам ВСУЗИ [6, 7], которые включают следующие операции:

1. Создание банка оцененных человеком изображений, полученных при ВСУЗИ и ОКТ, с точки зрения того, какой тип атеромы визуализируется — стабильный или нестабильный.

2. Формирование двух выборок изображений — со стабильными и нестабильными бляшками, которые, в свою очередь, делятся на две подгруппы каждая. Первая используется для обучения нейросети, а вторая — для ее тестирования.

Y. Bae et al. использовали данные, полученные в ходе проведения предоперационного ВСУЗИ и ОКТ у 517 пациентов в период с 2010 г. [6]. Разделение на обучающую и тестовую выборки производилось в соотношении 4 : 1 (соответственно 517 чел. : 103 чел.), с последующей их рандомизацией. Лучший результат, полученный в исследовании, составил 0.82 AUC. Результат работы алгоритма на фиксированной тестовой выборке визуализируют с помощью ROC-кривой (ROC — receiver operating characteristic curve, или кривая ошибок), а качество оценивают как площадь под этой кривой — AUC (area under the curve). AUC для оценки нейросети измеряется в следующих единицах: 0.5–1, где 0.5 — абсолютно случайный прогноз; 1 — истинный прогноз. Для искусственного интеллекта в медицинской диагностике нижним пределом допустимости можно считать 0.8 AUC. Применение нейросети в клинической практике имеет смысл только при достижении этого минимального значения.

T.J. Jun et al. в своем исследовании использовали данные, полученные при проведении ангиографии/ЧКВ у 100 пациентов. Лучший результат составлял 0.91 AUC [7].

Достаточно интересным нам представляется другой подход к обучению нейронных сетей, про-

ризм based on machine learning propose methods that will make it possible to assess not only the morphology of atheroma, but also its stability based on IVUS results [6].

Today, there are two algorithms for automated detection of vulnerable plaque based on IVUS results [6, 7], which include the following operations:

1. Creation of a bank of human-evaluated IVUS and OCT images, in terms of which type of atheroma is clearly visible — stable or unstable.

2. Formation of two sets of images — with stable and vulnerable plaques, which, in turn, are divided into two subgroups each. The first is used to train the neural network, and the second is used to test it.

Y. Bae et al. used the data obtained during pre-operative IVUS and OCT in 517 patients since 2010 [6]. The division into training and test sets was carried out in a ratio of 4 : 1 (respectively 517 people : 103 people), with their subsequent randomization. The best result in the study was 0.82 AUC. The result of the algorithm using for a test set is visualized with the ROC curve (ROC — receiver operating characteristic curve, or error curve), and the quality is assessed as the area under this curve — AUC (area under the curve). AUC for evaluating a neural network is measured in the following limits: from 0.5 to 1, where 0.5 is the absolutely random forecast; 1 — the true forecast. For artificial intelligence in medical diagnostics, the 0.8 AUC can be considered the lower limit of tolerance. The use of a neural network in clinical practice makes sense only when this minimum value is reached.

T.J. Jun et al. used data obtained from angiography/PCI in 100 patients. The best result was 0.91 AUC [7].

Another approach to neural networks learning, demonstrated in the work of Y. Cao et al. [8], who used not the OCT/IVUS image set for training the neural network, but a histological specimen/IVUS, seems to be quite interesting to us. Rabbits with atherosclerotic lesions of the aorta underwent IVUS *in vivo*. Then, histological specimens with a specific staining for lipids, macrophages, smooth muscle cells and collagen were made from the aortas of the same rabbits. Later, the images were grouped and the neural network was trained. This algorithm, therefore, does not use the detection of certain layers of the vascular wall, comparing their relationship and density, but a virtual histology. The best result in this study was 0.71 AUC, which can be explained by the extremely small sample size — only 23 rabbits. In the future, Y. Cao et al. plan to improve the algorithm on a larger sample and apply

демонстрированный в работе Y. Cao et al. [8], использовавших для обучения нейросети не группировку изображений ОКТ/ВСУЗИ, а гистологический препарат/ВСУЗИ. Прижизненно кроликам с атеросклеротическим поражением аорты провели ВСУЗИ. Затем из аорт этих же кроликов были изготовлены препараты со специфической окраской для липидов, макрофагов, волокон коллагена, гладкомышечных клеток. В дальнейшем произвели группировку изображений и обучили нейросеть. Данный алгоритм, таким образом, использует не выделение определенных слоев сосудистой стенки, сравнение их взаимосвязи и плотности, а виртуальную гистологию. Наилучший результат, полученный в данном исследовании, составил 0.71 AUC, что можно объяснить крайней малочисленностью выборки — всего 23 кролика. В будущем Y. Cao et al. планируют усовершенствовать алгоритм на большей выборке и применить данную нейросеть для оценки результатов ВСУЗИ, проведенного человеку.

АВТОМАТИЧЕСКОЕ ВЫДЕЛЕНИЕ ПРОСВЕТА И СЛОЕВ СОСУДИСТОЙ СТЕНКИ (СЕГМЕНТАЦИЯ) НА ИЗОБРАЖЕНИЯХ, ПОЛУЧЕННЫХ ПРИ ВСУЗИ

Обучение таких нейросетей производится по тому же принципу, что и для описанных выше, позволяющих обнаруживать нестабильные бляшки, но с той лишь разницей, что обучающие и тестовые выборки формируются из открытых источников изображений, полученных при ВСУЗИ. Необходимо отметить, что разработчики данного алгоритма представляют открытый исходный код своих программ, размещая в своих статьях ссылки на ресурсы для загрузки необходимого программного обеспечения, что позволяет всем заинтересованным самостоятельно оценить, как функционирует нейросеть [9]. Далее мы представим хронологию развития технологии и продемонстрируем результаты, чтобы показать эволюцию данных алгоритмов.

В декабре 2018 г. Y.Y. Wang et al. представили алгоритм для автоматического определения границы между медией и адвентицией коронарных сосудов [10] (рис. 1). Эта не первая по данной тематике публикация, однако мы считаем, что именно с нее следует начинать отсчет развития технологии автоматической сегментации сосудистой стенки, поскольку именно Y.Y. Wang et al. впервые решили проблему всех предыдущих нейросетей — невозможность провести сегментацию на участках бифуркации сосуда и атером с высоким содержанием кальция.

this neural network to assess the results of IVUS for humans.

AUTOMATIC EXTRACTION OF THE LUMEN AND LAYERS OF THE VASCULAR WALL (SEGMENTATION) IN IVUS IMAGES

Learning of such neural networks is carried out according to the same principle as for those described above, which allow detecting vulnerable plaques, but with the only difference that training and test sets are formed from open sources of IVUS images. It should be noted that the developers of this algorithm present the open source code of their programs, giving links to resources for downloading the necessary software in their articles, which allows everyone interested to independently evaluate how the neural network functions [9]. Next, we will present a chronology of the development of the technology and demonstrate the results to give an idea of these algorithms' evolution.

In December 2018, Y.Y. Wang et al. presented an algorithm for automatic determination of the border between the media and adventitia of the coronary vessels [10] (Fig. 1). This is not the first publication on the topic, however, we believe that it should be considered a starting point for the development of the technology of automatic segmentation of the vascular wall, since it is Y.Y. Wang et al. who were the first to solve the problem of all previous neural networks — the inability to perform segmenting in the areas of vessel bifurcation and high calcium atheromas.

In July 2019, J. Yang et al. published an article in which they presented the Dual Path U-Net neural network, which performs the same tasks as the previous one. The Dual Path U-Net also solves the problem of the complexity of segmentation at bifurcation sites and atheromas with advanced calcification [11]. J. Yang et al. also compared the results of segmentation performed by the neural network and a human (Fig. 2).

In July 2020, M. Xia et al. presented the MFAU-Net (multi-scale feature aggregated U-Net) neural network, which combines various types of neural networks and demonstrates the best segmentation results [12]. The key feature of this neural network is the possibility to get the result that is closest to one given by a person (Fig. 3).

PREDICTION OF THE FRACTIONAL FLOW RESERVE BASED ON INTRAVASCULAR ULTRASOUND

T.G. Papaioannou et al. developed an algorithm that allows, on the basis of IVUS images with




Рис. 1. Пример автоматического выделения границы между медией и адвентицией (синяя линия) на изображениях, полученных при ВСУЗИ [10]

Fig. 1. An example of automatic extraction of the media — adventitia border (blue line) in IVUS images [10]

В июле 2019 г. J. Yang et al. опубликовали статью, в которой представили нейросеть Dual Path U-Net, выполняющую те же задачи, что и предыдущая, тоже решающую проблему сложности сегментации на участках бифуркации и значительно кальцифицированных атером [11]. Также проводилось сравнение результатов сегментации, выполненной нейросетью и человеком (рис. 2).

В июле 2020 г. M. Xia et al. представили нейросеть MFAU-Net (multi-scale feature aggregated U-Net), объединяющую различные варианты нейросетей и демонстрирующую наилучшие результаты сегментации [12]. Ключевая особенность заключается в том, что данная нейросеть позволяет получить результат, наиболее близкий к тому, который дает человек (рис. 3).

virtual histology, to assess the morphology of the coronary bed lesion [13]. At the same time, in order to determine the indications for stenting in stable angina, in the absence of cardiac stress test data, an assessment of the fractional flow reserve (FFR) is required.

J.G. Lee et al. [14] used a neural network to assess FFR in the intermediate coronary artery. In the period from November 2009 to July 2015, 1657 stable and unstable angina patients were examined (329 patients were subsequently excluded from the study due to the multivessel lesions, presence of a stent within the target vessel, left main coronary artery stenosis more than 30%, and others reasons). Patients underwent coronary angiography and pre-operative IVUS to assess FFR in at least one inter-




Рис. 2. Пример автоматического выделения просвета и меди сосуда (желтая пунктирная линия — границы, обозначенные четырьмя независимыми экспертами; бирюзовый цвет — просвет сосуда; красный цвет — медиа) [11]
 Fig. 2. An example of automatic extraction of the lumen and media (yellow dashed line is the border indicated by four independent experts; turquoise color marks the vessel's lumen; red color highlights the media) [11]

ПРОГНОЗИРОВАНИЕ ФРАКЦИОННОГО РЕЗЕРВА КРОВОТОКА НА ОСНОВАНИИ ВНУТРИСОСУДИСТОГО УЛЬТРАЗВУКОВОГО ИССЛЕДОВАНИЯ

T.G. Papanicolaou et al. разработали алгоритм, позволяющий на основе изображений, полученных при ВСУЗИ с виртуальной гистологией, оценить морфологию поражения коронарного русла [13]. В то же время для определения показаний к проведению стентирования при стабильной стенокардии, при условии отсутствия данных стресс-тестов, требуется оценка фракционного резерва кровотока (ФРК).

J.G. Lee et al. использовали нейросеть для оценки ФРК в интермедиальной коронарной артерии. В период с ноября 2009 г. по июль 2015 г. обследовали 1657 пациентов со стабильной и нестабильной стенокардией (329 пациентов впослед-

mediate lesion (stenosis 40–80% according to angiography). Next, the data were randomized and distributed into training and test sets at a ratio of 4 : 1 (1063 people : 265 people). The following indicators were used: characteristics of plaque obtained during IVUS; age; gender; diabetes mellitus; current smoking; arterial hypertension; stable or unstable angina; body surface area; FFR at maximal hyperemia; involved segment (proximal/mid/distal of left anterior descending artery, proximal/distal of right coronary artery, proximal/distal of left circumflex artery). When testing the neural network all of the above data were provided with the exception of FFR respectively. The sensitivity of the method was 87%, AUC was 0.92 [14]. In the future, this group of researchers plans to continue their research in this area and confirm their results in a larger cohort.




Рис. 3. Примеры сегментации, проведенной с помощью MFAU-Net (зеленая пунктирная линия — вручную очерченная граница между просветом и интимой; пурпурная сплошная линия — автоматически очерченная граница между просветом и интимой; голубая пунктирная линия — вручную очерченная граница между медией и адвентицией; красная сплошная линия — автоматически очерченная граница между медией и адвентицией) [12]
 Fig. 3. Examples of segmentation with the MFAU-Net (green dashed line — manually delineated the lumen – intima border; purple solid line — automatically delineated the lumen – intima border; blue dashed line — manually delineated the media – adventitia border; red solid line — automatically delineated the media – adventitia border) [12]

ствии были исключены из исследования из-за многососудистого поражения, наличия стента внутри целевого сосуда, стеноза ствола левой коронарной артерии более 30 % и других причин). Пациентам была проведена инвазивная коронарография и предоперационное ВСУЗИ для оценки ФРК по крайней мере в одном промежуточном поражении (стеноз по данным ангиографии 40–80 %). Далее была произведена рандомизация и распределение данных на две выборки — обучающую и тестовую в соотношении 4 : 1 (1063 чел. : 265 чел.). Использовались следующие показатели: характеристики атеромы, полученные при проведении ВСУЗИ; возраст; пол; наличие сахарного диабета; курил ли пациент на момент проведения исследования; наличие артериальной гипертензии; стабильная или нестабильная стенокардия; площадь поверхности тела; ФРК при максимальной гиперемии; какой сегмент артерии поражен (проксимальный/средний/дистальный левой передней нисходящей артерии, проксимальный/дистальный правой коронарной артерии, проксимальный/дистальный левой огибающей артерии). При проведении тестирования нейросети предоставлялись все вышеперечисленные данные за исключением ФРК соответственно. Чувствительность метода составила 87 %, AUC — 0.92 [14]. В будущем эта группа исследователей планирует продолжить свои исследования в данной области и подтвердить свои результаты на большей когорте.

ЗАКЛЮЧЕНИЕ

В настоящее время применение нейросетей в оценке результатов внутрисосудистых ультразвуковых исследований является активно развивающимся направлением, однако его клиническая доказательная база крайне мала. Достижение при использовании нейросетей сопоставимой с человеком точности оценки может привести к уменьшению продолжительности проведения

CONCLUSION

Currently, the use of neural networks in assessing the results of intravascular ultrasound is an actively developing area, but its clinical evidence base is extremely small. Achievement of a human-like assessment accuracy using neural networks can improve the timing of percutaneous intervention. In addition, algorithms for the automatic detection of vulnerable plaque and prediction of the fractional flow reserve in the future can be combined, which unifies the use of intravascular ultrasound for various clinical situations. However, it should be understood that the use of artificial intelligence makes it possible to reveal various aspects of the pathological process, but does not negate the practice of making decisions about the effectiveness and safety of medical technologies based on the principles and methods of evidence-based medicine.

Conflict of interest. The authors declare no conflict of interest.

чрескожного вмешательства. Кроме этого, алгоритмы автоматического определения нестабильности бляшки и прогнозирования фракционного резерва кровотока в будущем могут быть объединены, что унифицирует использование внутрисосудистого ультразвукового исследования для различных клинических ситуаций. Однако следует понимать, что использование искусственного интеллекта позволяет детализировать различные аспекты патологического процесса, но не отменяет практики принятия решений об эффективности и безопасности медицинских технологий, основанной на принципах и методах доказательной медицины.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

СПИСОК ЛИТЕРАТУРЫ

1. Prajapati B.B., Parikh S.M., Pafel J.M. Effective healthcare services by IoT-based model of voluntary doctors // Data Science and Big Data Analytics. Lecture Notes on Data Engineering and Communications Technologies / D. Mishra, X.S. Yang, A. Unal (eds). Springer, Singapore, 2019. Vol. 16.
2. Яхонтов Д.А. Доказательная медицина в вопросах и ответах. Новосибирск, 2012. 326 с.
3. Benjamens S., Dhunoo P., Meskó B. The state of artificial intelligence-based FDA-approved medical devices and algorithms: an online database // npj Digit. Med. 2020. Vol. 3 (1): 118. doi: 10.1038/s41746-020-00324-0.

REFERENCES

1. Prajapati B.B., Parikh S.M., Pafel J.M. (2019). Effective healthcare services by IoT-based model of voluntary doctors. In Mishra D., Yang X.S., Unal A. (eds). Data Science and Big Data Analytics. Lecture Notes on Data Engineering and Communications Technologies. Springer, Singapore, 16.
2. Yakhontov D.A. (2012). *Evidence-based Medicine in Questions and Answers*. Novosibirsk, 326 p. In Russ.
3. Benjamens S., Dhunoo P., Meskó B. (2020). The state of artificial intelligence-based FDA-approved medical devices and algorithms: an online database. *npj Digit. Med.*, 3 (1): 118. doi: 10.1038/s41746-020-00324-0.

4. FDA. Artificial intelligence and machine learning in software as a medical devices? URL: <https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-software-medical-device#regulation>. Дата обращения: 17.03.2021.
5. Minchale A., Rodriguez B. Artificial intelligence for the electrocardiogram // *Nat. Med.* 2019. Vol. 25 (1). P. 22–23. doi: 10.1038/s41591-018-0306-1.
6. Bae Y., Kang S.J., Kim G. et al. Prediction of coronary thin-cap fibroatheroma by intravascular ultrasound-based machine learning // *Atherosclerosis*. 2019. Vol. 288. P. 168–174. doi: 10.1016/j.atherosclerosis.2019.04.228.
7. Jun T.J., Kang S.J., Lee J.G. et al. Automated detection of vulnerable plaque in intravascular ultrasound images // *Med. Biol. Eng. Comput.* 2019. Vol. 57 (4). P. 863–876. doi: 10.1007/s11517-018-1925-x.
8. Cao Y., Xiao X., Liu Z. et al. Detecting vulnerable plaque with vulnerability index based on convolutional neural networks // *Comput. Med. Imaging Graph.* 2020. Vol. 81: 101711. doi: 10.1016/j.compmedimag.2020.101711.
9. Lo Vercio L., Del Fresno M., Larrabide I. Lumen-intima and media-adventitia segmentation in IVUS images using supervised classifications of arterial layers and morphological structures // *Comput. Methods Programs Biomed.* 2019. Vol. 177. P. 113–121. doi: 10.1016/j.cmpb.2019.05.021.
10. Wang Y.Y., Qiu C.H., Jiang J., Xia S.R. Detecting the media-adventitia border in intravascular ultrasound images through a classification-based approach // *Ultrason. Imaging*. 2019. Vol. 41 (2). P. 78–93. doi: 10.1177/0161734618820112.
11. Yang J., Faraji M., Basu A. Robust segmentation of arterial walls in intravascular ultrasound images using Dual Path U-Net // *Ultrasonics*. 2019. Vol. 96. P. 24–33.
12. Xia M., Yan W., Huang Y. et al. Extracting membrane borders in IVUS images using a multi-scale feature aggregated U-Net // *Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.* 2020. P. 1650–1653. doi: 10.1109/EMBC44109.2020.9175970.
13. Papaioannou T.G., Schizas D., Vavuranakis M. et al. Quantification of new structural features of coronary plaques by computational post-hoc analysis of virtual histology-intravascular ultrasound images // *Comput. Methods Biomech. Biomed. Engin.* 2014. Vol. 17. P. 643–651. doi: <https://doi.org/10.1080/10255842.2012.713940>.
14. Lee J.G., Ko J., Hae H et al. Intravascular ultrasound-based machine learning for predicting fractional flow reserve in intermediate coronary artery lesions // *Atherosclerosis*. 2020. Vol. 292. P. 171–177.
4. FDA. Artificial intelligence and machine learning in software as a medical devices? Retrieved on March 17, 2021 from <https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-software-medical-device#regulation>.
5. Minchale A., Rodriguez B. (2019) Artificial intelligence for the electrocardiogram. *Nat. Med.*, 25 (1), 22–23. doi: 10.1038/s41591-018-0306-1.
6. Bae Y., Kang S.J., Kim G. et al. (2019). Prediction of coronary thin-cap fibroatheroma by intravascular ultrasound-based machine learning. *Atherosclerosis*, 288, 168–174. doi: 10.1016/j.atherosclerosis.2019.04.228.
7. Jun T.J., Kang S.J., Lee J.G. et al. (2019). Automated detection of vulnerable plaque in intravascular ultrasound images. *Med. Biol. Eng. Comput.*, 57 (4), 863–876. doi: 10.1007/s11517-018-1925-x.
8. Cao Y., Xiao X., Liu Z. et al. (2020). Detecting vulnerable plaque with vulnerability index based on convolutional neural networks. *Comput. Med. Imaging Graph.*, 81, 101711. doi: 10.1016/j.compmedimag.2020.101711.
9. Lo Vercio L., Del Fresno M., Larrabide I. (2019). Lumen-intima and media-adventitia segmentation in IVUS images using supervised classifications of arterial layers and morphological structures. *Comput. Methods Programs Biomed.*, 177, 113–121. doi: 10.1016/j.cmpb.2019.05.021.
10. Wang Y.Y., Qiu C.H., Jiang J., Xia S.R. (2019). Detecting the media-adventitia border in intravascular ultrasound images through a classification-based approach. *Ultrason. Imaging*, 41 (2), 78–93. doi: 10.1177/0161734618820112.
11. Yang J., Faraji M., Basu A. (2019). Robust segmentation of arterial walls in intravascular ultrasound images using Dual Path U-Net. *Ultrasonics*, 96, 24–33.
12. Xia M., Yan W., Huang Y. et al. (2020). Extracting membrane borders in IVUS images using a multi-scale feature aggregated U-Net. *Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, 1650–1653. doi: 10.1109/EMBC44109.2020.9175970.
13. Papaioannou T.G., Schizas D., Vavuranakis M. et al. (2014). Quantification of new structural features of coronary plaques by computational post-hoc analysis of virtual histology-intravascular ultrasound images. *Comput. Methods Biomech. Biomed. Engin.*, 17, 643–651. doi: <https://doi.org/10.1080/10255842.2012.713940>.
14. Lee J.G., Ko J., Hae H. (2020). Intravascular ultrasound-based machine learning for predicting fractional flow reserve in intermediate coronary artery lesions. *Atherosclerosis*, 292, 171–177.

СВЕДЕНИЯ ОБ АВТОРАХ

Мадонов Павел Геннадьевич — д-р мед. наук, профессор, заведующий кафедрой фармакологии, клинической фармакологии и доказательной медицины ФГБОУ ВО «Новосибирский государственный медицинский университет» Минздрава России.

Хидирова Людмила Даудовна — д-р мед. наук, доцент кафедры фармакологии, клинической фармакологии и доказательной медицины ФГБОУ ВО

ABOUT THE AUTHORS

Madonov Pavel Gennadyevich — Dr. Sci. (Med.), Professor, Head, Department of Pharmacology, Clinical Pharmacology and Evidence-Based Medicine, Novosibirsk State Medical University.

Khidirova Lyudmila Daudovna — Dr. Sci. (Med.), Assistant Professor, Department of Pharmacology, Clinical Pharmacology and Evidence-Based Medicine, Novosibirsk State Medical University.

«Новосибирский государственный медицинский университет» Минздрава России.

Ковалёв Евгений Александрович — студент VI курса ФГБОУ ВО «Новосибирский государственный медицинский университет» Минздрава России.

Образец цитирования: Мадонов П.Г., Хидирова Л.Д., Ковалёв Е.А. Возможности применения нейросетей в оценке результатов внутрисосудистого ультразвукового исследования (обзор литературы) // *Journal of Siberian Medical Sciences*. 2021. № 2. С. 127–135.

Kovalev Evgeniy Aleksandrovich — 6-year Student, Novosibirsk State Medical University.

Citation example: Madonov P.G., Khidirova L.D., Kovalev E.A. (2021). Possibilities of neural networks application in assessing the results of intravascular ultrasound (literature review). *Journal of Siberian Medical Sciences*, 2, 127–135.

