

DOI: 10.37988/1811-153X_2025_1_116

В.В. Шкарин,

д.м.н., профессор, зав. кафедрой общественного здоровья и здравоохранения Института непрерывного медицинского и фармацевтического образования (ИНМФО)

Ю.А. Македонова,

д.м.н., профессор, зав. кафедрой стоматологии ИНМФО

Е.Н. Ярыгина,

к.м.н., доцент, зав. кафедрой хирургической стоматологии и челюстно-лицевой хирургии

Л.Д. Вейсгейм,

д.м.н., профессор кафедры ортопедической стоматологии и ортодонтии ИНМФО

Д.Ю. Дьяченко,

к.м.н., доцент кафедры стоматологии ИНМФО

Л.М. Гаврикова,

к.м.н., доцент кафедры стоматологии ИНМФО

ВолГГМУ, 400066, Волгоград, Россия

ДЛЯ ЦИТИРОВАНИЯ:

Шкарин В.В., Македонова Ю.А., Ярыгина Е.Н., Вейсгейм Л.Д., Дьяченко Д.Ю., Гаврикова Л.М. Оценка диагностической возможности обученной нейросетевой модели в стоматологии. — Клиническая стоматология. — 2025; 28 (1): 116—123.

DOI: 10.37988/1811-153X_2025_1_116

Оценка диагностической возможности обученной нейросетевой модели в стоматологии

Реферат. Разработка нейросетей — актуальная задача в современной практике врача-стоматолога в связи с необходимостью достижения высоких показателей интерпретации рентгенологических снимков, сокращения времени на оформление первичной медицинской документации, снижения субъективной оценки при диагностике стоматологических заболеваний.

Цель работы — оценить диагностические возможности интерпретации рентгенологических снимков в стоматологии при помощи обученной нейросетевой модели. **Материалы и методы.**

В исследование были включены 300 ортопантомограмм (ОПТГ) пациентов, на которых было изображено не менее 5 зубов без учета их групповой принадлежности. Снимки случайным образом распределили на 3 группы: I — 200 снимков для обучения нейросетевой модели, II — 50 снимков для контроля модели в процессе обучения, III — 50 снимков для ручной разметки врачами-стоматологами (группа сравнения). Для обучения были выбраны 5 доступных нейросетевых моделей «You Only Look Once» v8 с открытым исходным кодом и различным скоростью операций с плавающей точкой: 12, 42, 110, 220 и 344 Гфлопс. Каждая модель обучалась в течение 5000 эпох с регистрацией промежуточных вариантов обученной модели каждые 100 эпох. **Результаты.** Применение нейросетей в задачах определения различных рентгеноконтрастных структур на ОПТГ выявляет объекты с точностью 0,98 при условии достаточного количества объектов в обучающей выборке. Увеличение количества эпох обучения увеличивает качество детектирования каждого объекта (0,875) и его сегментации (0,947) до пиков значений к 2500 эпох и становится практически неизменным при дальнейшем обучении. Увеличение параметра быстродействия модели целесообразно до значений 42 Гфлопс, дальнейшее повышение показателя не выявило диагностической ценности. В сравнении с врачами-стоматологами нейросеть показала значительный прирост в скорости обработки одного снимка, примерно в 25 раз быстрее человека, а качество детектирования врачами лучше на 1%, но больший вклад в ошибку внесен объектами, требующими увеличение обучающей выборки, что в очередной раз подтверждает необходимость правильного формирования обучающего набора данных. **Заключение.** Применение нейросети с обученной моделью для детектирования и интерпретации рентгенологических снимков в стоматологии показала высокую диагностическую ценность. Для условий определения и сегментации объектов целесообразно использовать модели таких размеров, которые позволяют обрабатывать объекты с высокой степенью достоверности. Обязательным условием достижения высоких результатов является достаточная обучающая выборка, которая в должной мере способствует повышению качества детектирования объектов и их границ на рентгенологических исследованиях.

Ключевые слова: нейросетевая модель в стоматологии, детектирование объектов, ортопантомограмма

Evaluation of the diagnostic capability of a trained neural network model in dentistry

Abstract. The development of neural networks is an urgent task in the modern practice of a dentist due to the need to achieve high rates of interpretation of X-ray images, reduce the time for processing primary medical documentation, and reduce subjective assessment in the diagnosis of dental diseases. **The aim of the work** is to evaluate the diagnostic possibilities of interpreting X-ray images in dentistry using a trained neural network model. **Materials and methods.** The study included 300 OPTG patients who had at least 5 teeth without taking into account their group affiliation. The images were randomly divided into 3 groups: I — 200 images for training the neural network model, II — 50 images for monitoring the model during training, III — 50 images for manual marking by dentists (comparison group). Five available “You Only Look Once” v8 neural network models with open source code and different floating-point operation speeds were selected for training: 12, 42, 110, 220 and 344 Gflops. Each model was trained for 5,000 epochs with the registration of intermediate variants of the trained model every 100 epochs. **Results.** The use of neural networks in the tasks of determining various X-ray contrast structures at the optical imaging

V.V. Shkarin,

Doctor of Science in Medicine, full professor of the Public health and health care Department

Yu.A. Makedonova,

Doctor of Science in Medicine, full professor of the Dentistry Department

E.N. larygina,

PhD in Medical Sciences, associate professor and head of the Oral and maxillofacial surgery Department

L.D. Veisgeim,

Doctor of Science in Medicine, professor of the Prosthodontics and orthodontics Department

D.Yu. Dyachenko,

PhD in Medical Sciences, associate professor of the Dentistry Department

L.M. Gavrikova,

PhD in Medical sciences, associate professor of the Dentistry Department

Volgograd State Medical University,
400066, Volgograd, Russia**FOR CITATION:**

Shkarin V.V., Makedonova Yu.A., larygina E.N., Veisgeim L.D., Dyachenko D.Yu., Gavrikova L.M. Evaluation of the diagnostic capability of a trained neural network model in dentistry. *Clinical Dentistry (Russia)*. 2025; 28 (1): 116—123 (In Russian). DOI: 10.37988/1811-153X_2025_1_116

laboratory identifies objects with an accuracy of 0.98, provided there are a sufficient number of objects in the training sample. An increase in the number of training epochs increases the quality of detection of each object (0.875) and its segmentation (0.947) to peak values by 2500 epochs and becomes almost unchanged with further training. An increase in the model's performance parameter is advisable to values of 42 Gflops, a further increase in the indicator did not reveal diagnostic value. In comparison with dentists, the neural network showed a significant increase in the processing speed of a single image, about 25 times faster than a human, and the quality of detection by doctors is 1% better, but a greater contribution to the error was made by objects requiring an increase in the training sample, which once again confirms the need for proper formation of the training dataset. **Conclusion.** The use of a neural network with a trained model for the detection and interpretation of X-ray images in dentistry has shown high diagnostic value. For the conditions for defining and segmenting objects, it is advisable to use models of such sizes that allow processing objects with a high degree of confidence. A prerequisite for achieving high results is a sufficient training sample, which contributes to improving the quality of detection of objects and their boundaries in X-ray studies.

Key words: neural network model in dentistry, object detection, orthopantomogram

ВВЕДЕНИЕ

В последние несколько лет особое развитие в медицине получили методы компьютерного зрения и алгоритмы анализа плоскостных и объемных данных. Это связано не только с прорывным развитием аппаратных технологий обработки массивов данных, но и с внедрением технологий распознавания электронно-вычислительными машинами контекста и нелинейной обработки данных. Одним из ярких примеров подобной технологии в стоматологии можно считать технологии сверточных нейронных сетей, представляющих собой революционную трансформацию компьютерного анализа [1, 2]. Они позволяют обучить математическую модель проведению анализа, поиска, идентификации и сегментации объектов в исходных массивах данных. Алгоритмы глубокого обучения по своему принципу работы схожи с работой мозга человека и подходом к анализу визуальных образов [3]. Они предоставляют возможность выявить ключевые маркеры и группы объектов, которые ранее нейросетевая модель встречала в процессе обучения [4]. Наглядной демонстрацией практического применения технологии может служить рентгенологическое исследование, которые являются двухмерным массивом пикселей (прицельная внутритротовая рентгенография, ортопантомография и т.д.) или трехмерным массивом вокселей (конусно-лучевая компьютерная или магнитно-резонансная томография и т.д.). Однако, несмотря на постоянное совершенствование рентгенологических методик, анализ и интерпретация данных проводятся врачом-специалистом при помощи визуального восприятия изображения. В отечественных и зарубежных публикациях описаны возможные трудности интерпретации рентгенологических снимков [5]. Недостаточная и/или неправильная диагностика оказывает значительное влияние на дальнейший прогноз лечения заболевания полости рта.

С целью повышения диагностической ценности исследований в качестве системы поддержки принятия решений можно использовать компьютерные технологии, в том числе нейронные сети [6]. При условии множества факторов: адекватного обучения математической модели, достаточного объема обучающей выборки, точности

создания обучающего набора и других факторов, — можно добиться высоких показателей достоверности при анализе рентгенологических снимков. Применение подобных технологий может способствовать расширению диагностических возможностей на стоматологическом приеме.

Однако в стоматологии остро ощущается дефицит свободного доступа к диагностическим нейросетям, направленным на интерпретацию рентгенологических изображений [7]. Разработка и обучение данных систем является актуальной задачей в современной практике врача-стоматолога.

Цель исследования — оценить диагностические возможности интерпретации рентгенологических снимков в стоматологии при помощи обученной нейросетевой модели.

МАТЕРИАЛЫ И МЕТОДЫ

Проведено рандомизированное контролируемое исследование 334 ортопантомограмм (ОПТГ) пациентов от 18 до 74 лет не менее чем с 5 зубами в полости рта и без признаков патологии костной ткани на рентгеновском снимке. Отбор ОПТГ проводили при обследовании пациентов на базе Волгоградской областной клинической стоматологической поликлиники с февраля по апрель 2024 г. После первичного отсея в рамках разработки нейросети и обучения модели для врачей-стоматологов в работу было включено 300 ОПТГ (рис. 1).

Распределение между первой и второй группами находилось в общепринятое соотношении 80:20, в соответствии с правилами обучения нейросетевых моделей: 80% от всех исходных данных, причисленных к обучающей выборке, помещается в группу обучения, 20% — в группу контроля обучения для отслеживания качества полученной модели [8–10].

Рандомизация ОПТГ осуществлялась по написанному нами алгоритму, который позволил сформировать группы таким образом, чтобы распределение всех объектов интереса между 3 группами стремилось к соотношению 4:1:1:

1 — 200 уникальных ОПТГ, на которых нейросетевая модель обучалась в течение каждой эпохи;

- II — 50 ОПТГ — контроль обучения модели
 III — 50 ОПТГ для оценки возможности применения нейросетевой модели диагностики в стоматологии.

Это позволило распределить все детектированные объекты на ОПТГ по группам с указанным ранее соотношением и предотвратить случаи попадания объектов с меньшей частотой встречаемости в одну группу и полное отсутствие их в других. Все обучающие данные были подвергнуты дополнительной обработке в процессе обучения модели для увеличения выборки.

На всех снимках объектами исследования для идентификации были приняты моляры, премоляры, клыки и резцы верхней и нижней челюсти, а также коронки, искусственные зубы, корни, штифтово-кульевые конструкции, металлические штифты, дентальные имплантаты и пломбы. Зубы были разделены по принципу функциональной принадлежности для каждой челюсти, корни зубов относили в отдельную группу при разрушении коронковой части более 50% от визуализируемой площади.

Ручная цифровая разметка проводилась исследователями на основе рентгенологической картины пациента и данных клинического осмотра для составления полной картины клинической ситуации. Процедура включала обведение контуров твердых тканей, а также иных рентгеноконтрастных элементов: реставраций, ортопедических конструкций и др. В случае конфликта границ объектов различной групповой принадлежности максимально сохранялись визуализируемые границы и идентифицировались все доступные объекты: например зуб, покрытый коронкой, отмечался как зуб соответствующей функциональной группы и отдельно детектировалась коронка (рис. 2). В ходе работы было идентифицировано 11 385 объектов.

Далее было проведено сравнительное исследование на 5 моделях нейронной сети «You Only Look Once» v8 с открытым исходным кодом и различным уровнем производительности средствами глубокого машинного обучения. Нейросеть запускали на компьютере с процессором i5-11900KF, 32 Гб оперативной памяти DDR4, видеокартой NVIDIA GeForce RTX 4080 с 16 Гб памяти под управлением Windows 10. Код выполняли в среде Python 3.11 с библиотекой PyTorch 1.9.1 и пакетом torchvision 0.15.0. В ходе обучения для сокращения времени обучения задействовали NVIDIA CUDA 11.3 с применением графического процессора. Нейросетевые



Рис. 1. Дизайн исследования

Fig. 1. Study design

модели были разделены по скорости выполнения операций с плавающей запятой: nano (N), small (S), medium (M), large (L) и extra-large (X; табл. 1).

В ходе исследования проводилось обучение каждой модели нейронной сети с ОПТГ из I группы. Контроль обучения проводился на каждой эпохе при помощи

Таблица 1. Характеристика различных моделей нейронных сетей
 Table 1. Characteristics of various neural network models

Модель	Производительность, Гфлопс	Размер входного изображения для обучения, пикс.	Скорость работы нейросети на процессоре, мс
Nano	12,6	640	96,1
Small	42,6	640	155,7
Medium	110,2	640	317,0
Large	220,5	640	572,4
Extra-large	344,1	640	712,1



Рис. 2. Предварительный этап обучения нейросети. Пациент Б., 44 года: А — ОПТГ (исходные данные), В — разметка рентгеноконтрастных структур в зависимости от класса принадлежности

Fig. 2. Preliminary stage of neural network training. Patient B., 44 years old: A — Orthopantomogram (initial data), B — Marking of radiopaque structures depending on the class of belonging

II группы. Каждая нейросетевая модель обучалась в течение 5000 эпох, что является двукратным увеличением количества необходимых эпох до достижения пиковых значений результатов обучения. Одна эпоха соответствует процессу прохождения нейронной сети по всему набору обучающей выборки (обучение на 200 снимках первой группы и замер качества модели на II группе). Каждая модель обучалась в течение 5000 эпох с регистрацией промежуточных вариантов весовых коэффициентов обученной модели каждые 100 эпох.

Далее, после пройденного обучения каждой модели, был проведен сравнительный анализ точности детектирования и сегментации ОПТГ для каждой модели (выбирали варианты моделей с наилучшими показателями контроля обучения). Сравнивали результат работы нейросети со вручную размеченными границами ОПТГ III группы.

Следующим этапом стало проведение сравнительного анализа качества и скорости работы с врачами-стоматологами. Для этого в процессе проверки работы модели на III группе сохранялись данные, полученные при детектировании объектов, а также время, затраченное нейросетью на работу с ОПТГ. В сравнительном анализе исследования приняло участие 10 врачей-стоматологов. В ходе исследования они должны были записать зубную формулу на основе данных ОПТГ, учитывая все объекты исследования. Помимо зубной формулы, регистрировалось время, затраченное на анализ ОПТГ.

Для анализа качества обучения нейросетевой модели были приняты следующие показатели исхода исследования: точность каждой нейросетевой модели, отзыв модели, точность идентификации и точность сегментации объекта на снимке. Для работы нейросети с врачами-стоматологами были приняты следующие показатели исхода исследования: время, затраченное на распознавание, а также запись зубной формулы по ОПТГ, качество детектирования структур на рентгенограмме.

Таблица 2. Суммарное количество выделенных объектов на ОПТГ

Table 2. Total number of selected objects in orthopantomographic studies

Объект	I группа		II группа		III группа	
	абс.	%	абс.	%	абс.	%
Моляры верхней челюсти	832	7,31	207	1,82	206	1,81
Премоляры верхней челюсти	610	5,36	155	1,36	154	1,35
Клыки верхней челюсти	378	3,32	93	0,82	95	0,83
Резцы верхней челюсти	735	6,46	187	1,64	182	1,60
Моляры нижней челюсти	842	7,40	208	1,83	211	1,85
Премоляры нижней челюсти	721	6,33	176	1,55	182	1,60
Клыки нижней челюсти	406	3,57	102	0,90	106	0,93
Резцы нижней челюсти	794	6,97	201	1,77	201	1,77
Коронки	891	7,83	227	1,99	222	1,95
Искусственные зубы	124	1,09	29	0,25	27	0,24
Корни	246	2,16	59	0,52	64	0,56
Штифтово-кульевые конструкции	190	1,67	48	0,42	52	0,46
Металлические штифты	18	0,16	3	0,03	5	0,04
Дентальные имплантаты	29	0,25	6	0,05	8	0,07
Пломбы	772	6,78	191	1,68	190	1,67

В ходе обучения нейросети были оценены дополнительные показатели процесса обучения нейросетевой модели: время, необходимое для достижения требуемого количества эпох обучения, объем задействованной видеопамяти и среднее значение потери пакета сегментации во время проверки.

При статистической обработке данных использовали методы вариационной статистики, различие между сравниваемыми показателями считалось достоверным при $p < 0,05$.

РЕЗУЛЬТАТЫ

Группа обучения, группа контроля и группа сравнения характеризовались сопоставимостью по изучаемым рентгеноконтрастным структурам. Всего было выделено 11 385 объектов (табл. 2). Анализ точности определения модели и ее отзыва представлен на рис. 3.

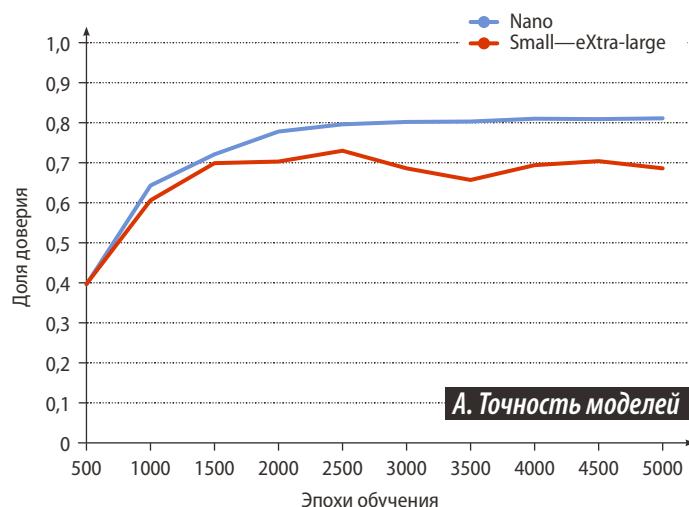


Рис. 3. Точность (A) и отзыв моделей (B) при пороге доверия 0,05

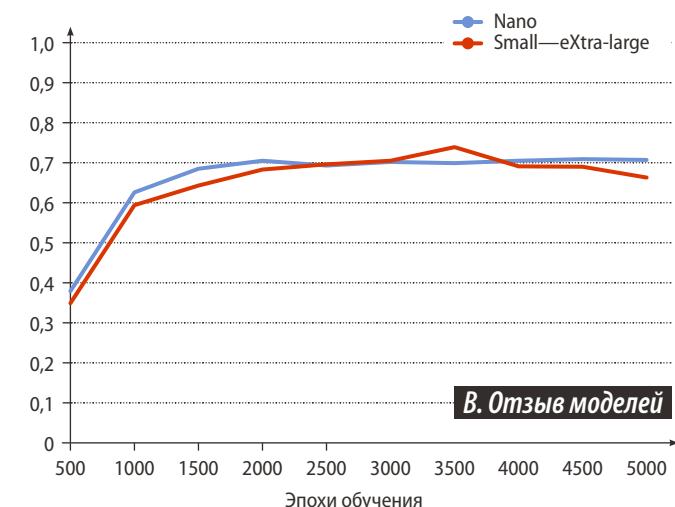


Fig. 3. Model accuracy (A) and recall (B) at a confidence threshold of 0,05

В процессе анализа среднего значения потери пакета сегментации во время проверки точности и отзыва модели было выявлено, что модели S, M, L, X идентичны, поэтому на графике они отражены одной линией.

При анализе работы различных моделей на ОПТГ III группы, которые нейросетевая модель не встречала в ходе этапа обучения, было выявлено, что присутствуют значительные различия обнаружения, детектирования и сегментации объектов в сравнении эпох обучения с 500 по 2500 во всех моделях нейросети, а также имеются меньшие по значению, но детектируемые изменения при сравнении эпох обучения с 2500 по 5000 (табл. 3).

На основе данных рентгенологического исследования пациентов I группы выявили четкую закономерность: при увеличении количества эпох пропорционально увеличиваются временные затраты цифрового оборудования (табл. 4.).

Среднее значение потери пакета сегментации во время проверки всех нейросетевых моделей примерно одинаково на всех этапах (рис. 4.).

Таблица 3. Данные результатов работы нейросети и описание ОПТГ III группы

Table 3. Data from the results of the neural network and description of orthopantomograms of the third group

	Врачи-стоматологи	Нейросеть, модель N	Нейросеть, модели S—X
Средняя скорость чтения ортопантомограммы и запись ее зубной формулы, секунды	51,82±2,17	1,86±0,17	2,01±0,16
Точность определения объектов на снимках	0,99±0,01	0,95±0,02	0,98±0,01

Таблица 4. Результаты обучения нейросетевой модели

Table 4. Neural network model training results

Модель	Время обучения, секунды			Средний объем видеопамяти для всех эпох, Гб
	500 эпох	2500 эпох	5000 эпох	
N	1987	7534	14741	9,47±0,86
S	1927	7397	14302	9,73±0,72
M	1981	7459	14422	9,84±0,91
L	1748	7400	14478	9,97±0,90
X	1328	6782	13940	10,1±0,92

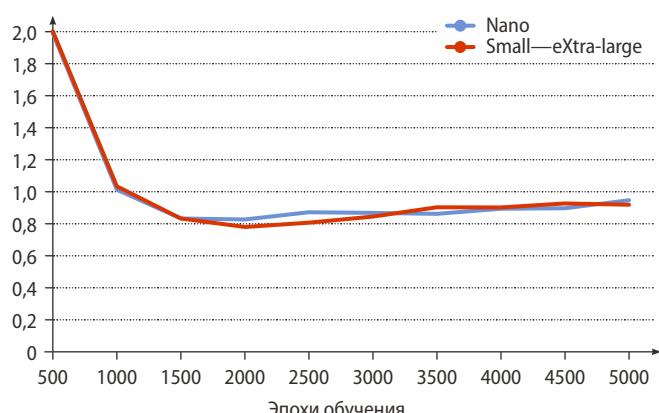


Рис. 4. Среднее значение потери пакета сегментации во время проверки в процессе обучения различных моделей
Fig. 4. Average segmentation packet loss during validation during training of different models

ОБСУЖДЕНИЕ

Результаты исследования подтверждают возможность применения нейросетевых моделей на основе глубокого обучения для применения их в задачах идентификации различных стоматологических структур и образований на ОПТГ.

Небольшой объем выборки исследования не может способствовать переносу полученных результатов на генеральную совокупность.

В ходе исследования процесса обучения нейросетевой модели были получены результаты, что размер модели, номер эпохи влияет незначительно на скорость прохождения одной эпохи, а это позволяет детально просчитать скорость обучения и спрогнозировать необходимое время обучения.

Учитывая, что в процессе анализа моделей было выявлено, что модели S, M, L и X идентичны. Это вызвано избыточностью замера алгоритма моделей M, L и X для поставленной задачи и в дальнейшем они не рассматривались для обсуждения. Все результаты обсуждения были интерпретированы на модель S-типа.

Результат анализа нейросетевых моделей в III группе показал, что объекты, у которых выборка была ограничена небольшим набором исходных данных для обучения, плохо идентифицируются на снимках (дентальный имплантат, анкерный штифт). Трудности в интерпретации объектов также встречаются у корней и штифтово-культиевых конструкций, это вызвано не только недостаточным количеством выборки, но и схожестью клинической ситуации: корень может быть часто интерпретирован неправильно и детектирован как зуб, покрытый коронкой или большим объемом пломбировочного материала, в этот же момент штифтово-культиевая конструкция визуально на ОПТГ по виду схожа с запломбированным корневым каналом, а также ее часть всегда перекрыта коронкой, что ограничивает интерпретацию ее границы. Сложности возникают при интерпретации больших реставраций из пломбировочного материала — это связано с его схожестью с коронками на рентгенограмме, или граница наложения на снимке контактов двух интактных зубов может быть идентифицирована как пломба. Эти и подобные случаи требуют увеличения исходной выборки, доработки алгоритма идентификации и обязательной индивидуальной интерпретации, что позволит повысить точность интерпретации (рис. 5, 6).

Анализ работы нейросети с различными моделями и дифференцированным их обучением показал, что более высокое качество детектирования достигается при определенных значениях размера модели и количества эпох обучения (при условии статистического порога доверия 0,05), что наглядно продемонстрировано на рис. 7 и 8.

Все вышесказанное гармонично дополняется результатами анализа группы сравнения, показывающего, что к 2500 эпох достигается достаточная точность

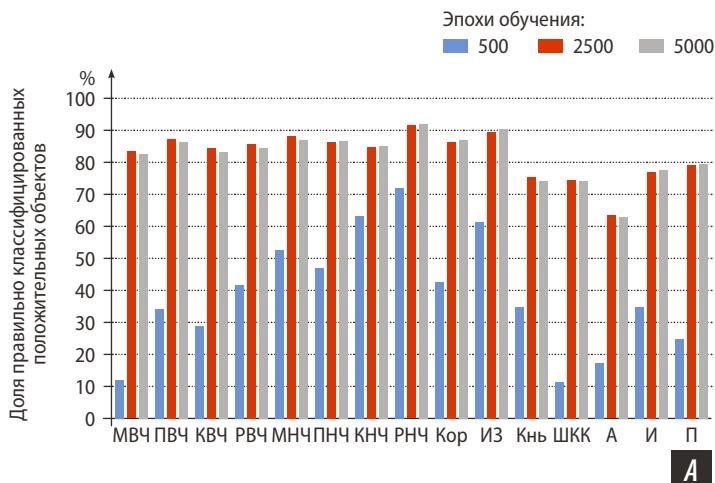


Рис. 5. Сравнение результатов идентификации объектов нейросетевой моделью с эталонными значениями на основе данных III группы: А — N-модели, В — S, M, L и X-модели. Различия данных N-модели статистически достоверно значимы по сравнению с данными остальных моделей одного периода обучения ($p<0,05$)

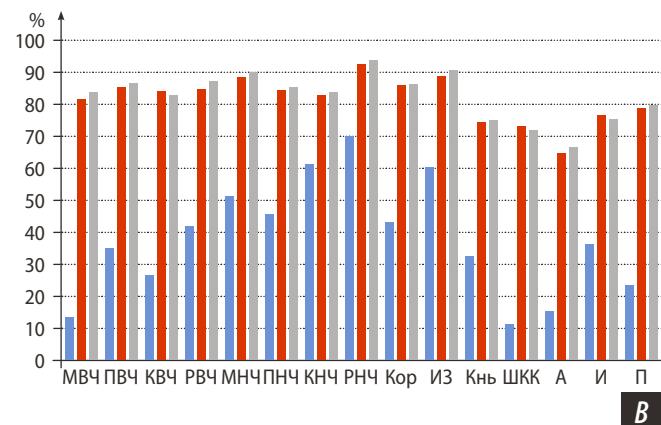


Fig. 5. Comparison of the results of object identification by the neural network model with reference values based on data from group 3: A — N-model, B — S, M, L, and X models. The differences of the N-model data are statistically significant compared to the data of the other models of the same training period ($p<0.05$)

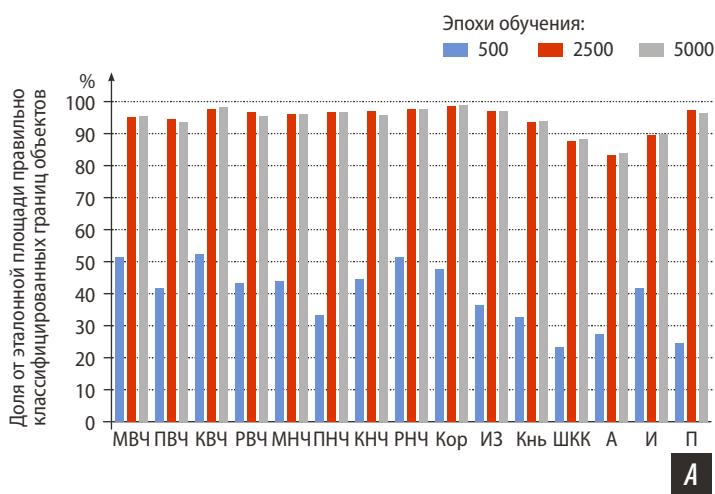


Рис. 6. Сравнение результатов идентификации границ объектов нейросетевой моделью с эталонными значениями на основе данных III группы: А — N-модель, В — S, M, L, и X-модели. Различия данных N-модели статистически достоверно значимы по сравнению с данными остальных моделей одного периода обучения ($p<0,05$)

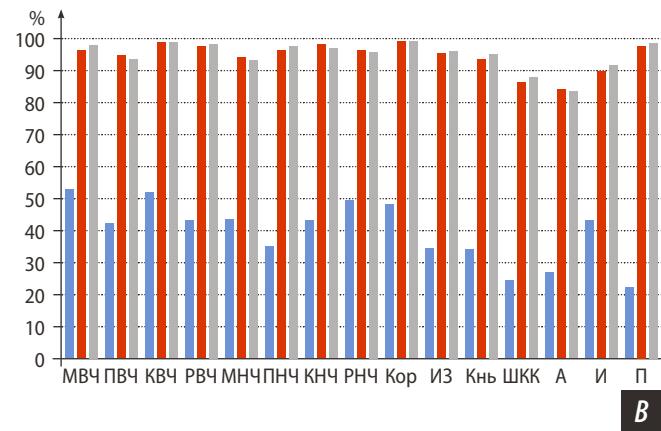
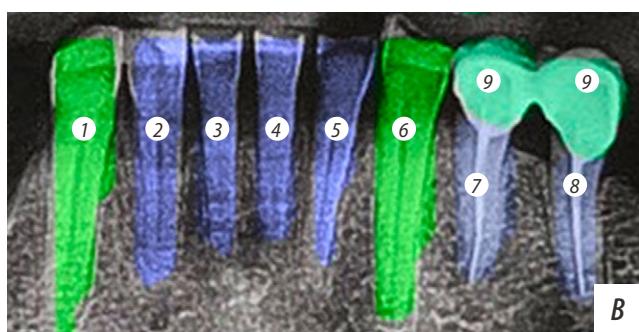


Fig. 6. Comparison of the results of identifying object boundaries using a neural network model with reference values based on data from group 3: A — N-model, B — S, M, L, and X models. The differences of the N-model data are statistically significant compared to the data of the other models of the same training period ($p<0.05$)



A

Рис. 7. Динамика изменения качества работы алгоритма S-модели при увеличении эпох обучения: А — 2000 эпох обучения, В — 3500 эпох обучения. Обозначения: 1 — зуб 4.3 идентифицирован как клык нижней челюсти; 2—5 — резцы нижней челюсти (4.2, 4.1, 3.1, 3.2); 6 (А) — зуб 3.3 идентифицирован как резец нижней челюсти; 7 (А) — зуб 3.4 идентифицирован как премоляр нижней челюсти, коронка не идентифицирована; 7 (В) — зуб 3.4 идентифицирован как премоляр нижней челюсти, коронка идентифицирована; 8 — зуб 3.5 идентифицирован как премоляр нижней челюсти; 9 — коронка



B

Fig. 7. Dynamics of changes in the quality of the S-model algorithm with increasing learning epochs: A — 2000 epochs of learning, B — 3500 epochs of learning). Labels: 1 — tooth 4.3 identified as the canine of the lower jaw; 2—5 — incisors of the lower jaw (4.2, 4.1, 3.1, 3.2); 6 A — tooth 3.3 identified as the incisor of the lower jaw; 7 A — tooth 3.4 identified as the premolar of the lower jaw, the crown is not identified; 7 B — tooth 3.4 identified as the premolar of the mandible, the crown is identified; 8 — tooth 3.5 identified as the premolar of the mandible; 9 — crown

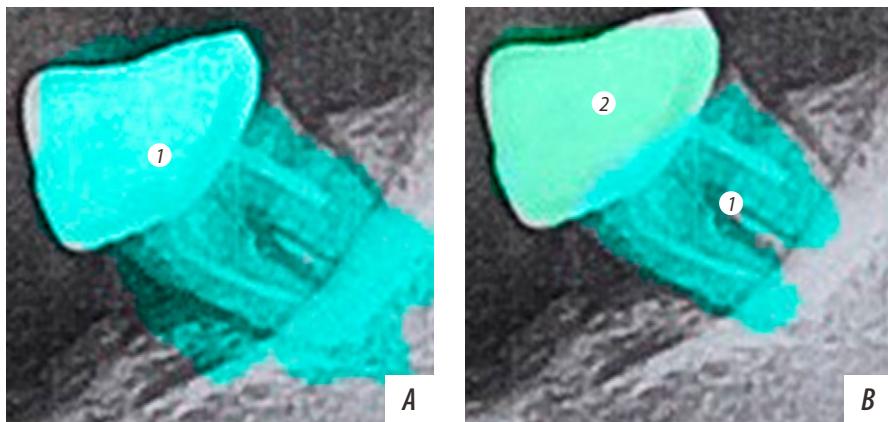


Рис. 8. Динамика изменения качества работы для разных нейросетевых моделей в условиях равного количества (2500 эпох) обучения в области зуба 3.7: А — N-модель, В — S модель. Обозначения: 1 А — зуб 3.7 идентифицирован, как моляр нижней челюсти, контур в неправильных границах; 1 В — зуб 3.7 идентифицирован, как моляр нижней челюсти, контур в правильных границах; 2 В — коронка

у большинства объектов с большим количеством исходного материала для обучения в обеих моделях (N и S), однако, у объектов с малым количеством исходного материала для обучения алгоритма замечено снижение качества идентификации объекта и его границ [11, 12].

Данные сравнительного анализа работы нейросетевого алгоритма с врачами-стоматологами продемонстрировали значительное сокращение среднего времени, необходимого на детектирование и описание одного снимка в 27,81 раз для нейросетевой модели N-типа и в 25,77 раз для нейросетевых моделей S—X-типа. Однако следует отметить, что качество детектирования было на 3,66% меньше для нейросетевой модели N-типа по сравнению с врачами и на 1,06% меньше для нейросетевой модели X-типа по сравнению с врачами. Замечено, что сложности в детектировании для нейросетей вызывают зубы, ранее леченные по поводу осложненного кариеса, с запломбированными корневыми каналами и аналогичные зубы, но с установленными в них штифтово-кульцевыми конструкциями и покрытые коронкой. В такой клинической ситуации больше всего допустили ошибку врачи-стоматологи (13% ошибок), нейросетевая модель N-типа — 17%, и S—X-модели 12% ошибок. Такую большую долю ошибок можно связать с размером выборки в 52 искомых элементах на всю III группу. Также врачи-стоматологи допустили ошибки при детектировании пломб в 2,63% случаев, а нейросеть в 1,59% и 0,53% случаев для N- и S—X-моделей соответственно.

Особый вклад в снижение показателей качества детектирования объектов при сравнительном анализе внесли анкерные штифты по причине малой выборки группы (5 элементов в III группе). Врачи-стоматологи смогли выявить все 5 анкерных штифтов, что соответствует 100%, однако ошибка детектирования в два элемента для N-модели и в один — для S—X-моделей привела к показателям точности в 60 и 80%, соответственно. Это еще раз подтверждает необходимость формирования

Fig. 8. Dynamics of changes in the quality of work for different neural network models under conditions of an equal 2500 epochs of learning in the tooth 3.7: A — N-model, B — S-model. Labels: 1 A — tooth 3.7 identified as a mandibular molar, the contour is not in the correct boundaries; 1 B — tooth 3.7 identified as a mandibular molar, the contour is in the correct boundaries; 2 B — crown

достаточного размера обучающей выборки и выбора нейросетевой модели требуемого размера.

ЗАКЛЮЧЕНИЕ

Учитывая полученные результаты исследования, можно сделать вывод, что обученные нейросетевые модели диагностики можно применять для детектирования и интерпретации рентгенологических снимков в стоматологии.

Для условий определения и идентификации объектов на плоскостных рентгенограммах целесообразно использовать нейросетевые модели средних размеров. Обязательным условием достижения высоких результатов является достаточная по размерам обучающая выборка, которая в должной мере способствует повышению качества детектирования объектов и их границ.

Учитывая тот факт, что нейросеть позволяет значительно сократить время диагностики, сохраняя точность детектирования, сопоставимую с врачами-стоматологами, применение нейросетевых моделей на клиническом приеме может позволить врачу сократить время, необходимое для работы с медицинской документацией, повысить качество диагностики рентгенологических снимков, а также исключить фактор субъективного анализа.

ФИНАНСИРОВАНИЕ

Исследование проведено в рамках реализации гранта РНФ № 24-25-20098 и Соглашения № 10 о предоставлении субсидий из областного бюджета (Волгоградская обл.) от 31.05.2024.

FUNDING

Russian Science Foundation grant No. 24-25-20098 and the Agreement No.10 on the provision subsidies from the regional budget (Volgograd region) dated 05/31/2024.

Поступила/Received: 30.06.2024

Принята в печать/Accepted: 14.02.2025

ЛИТЕРАТУРА:

1. Казарян Г.Г., Бекреев В.В., Иванов С.Ю., Оборотистов Н.Ю., Гусаров А.М., Хлыстова Т.В., Иванова И.В., Солошенков П.П., Цай П.А., Кибардин И.А. Возможности ультразвуковой диагностики и применения искусственной нейронной сети для оценки морфологии и размеров суставного диска височно-нижнечелюстного сустава. — *Клиническая стоматология*. — 2024; 1: 54—59. [eLibrary ID: 63433208](#)
2. Мураев А.А., Гусейнов Н.А., Цай П.А., Кибардин И.А., Буренчев Д.В., Иванов С.С., Оборотистов Н.Ю., Матюта М.А., Гречев Н.С., Ларин С.С. Искусственные нейронные сети в лучевой диагностике, в стоматологии и в челюстно-лицевой хирургии (обзор литературы). — *Клиническая стоматология*. — 2020; 3 (95): 72—80. [eLibrary ID: 44008071](#)
3. Lin C., Huang Y., Wang W., Feng S., Feng S. Lesion detection of chest X-Ray based on scalable attention residual CNN. — *Math Biosci Eng.* — 2023; 20 (2): 1730—1749. [PMID: 36899506](#)
4. Yu G., Sun K., Xu C., Shi X.H., Wu C., Xie T., Meng R.Q., Meng X.H., Wang K.S., Xiao H.M., Deng H.W. Accurate recognition of colorectal cancer with semi-supervised deep learning on pathological images. — *Nat Commun.* — 2021; 12 (1): 6311. [PMID: 34728629](#)
5. Рогацкин Д.В., Гелетин П.Н. Оптимизация алгоритма внутриротовой рентгенографии многокорневых зубов на примере первых моляров верхней челюсти и моляров нижней челюсти с radix entomolaris. Часть 1. — *Клиническая стоматология*. — 2023; 2: 16—23. [eLibrary ID: 54167521](#)
6. Леваньков Б.В., Выборов Е.М., Яковенко Н.И. Система поддержки принятия врачебных решений в медицинской диагностике на основе байесовских сетей. — *Известия Российской военно-медицинской академии*. — 2020; 4: 39—43. [eLibrary ID: 48033883](#)
7. Шанина А.Ю. Применение искусственного интеллекта в стоматологии. — *Международный научно-исследовательский журнал*. — 2023; 6 (132): . [eLibrary ID: 54052633](#)
8. Guefrechi S., et al. Deep learning based detection of COVID-19 from chest X-ray images. — *Multimed Tools Appl.* — 2021; 80 (21—23): 31803—31820. [PMID: 34305440](#)
9. Ranjbarzadeh R., Bagherian Kasgari A., Jafarzadeh Ghoushchi S., Anari S., Naseri M., Bendechache M. Brain tumor segmentation based on deep learning and an attention mechanism using MRI multi-modalities brain images. — *Sci Rep.* — 2021; 11 (1): 10930. [PMID: 34035406](#)
10. Рогацкин Д.В., Гелетин П.Н. Оптимизация алгоритма внутриротовой рентгенографии многокорневых зубов на примере первых моляров верхней челюсти и моляров нижней челюсти с radix entomolaris. Часть 2. — *Клиническая стоматология*. — 2023; 3: 6—13. [eLibrary ID: 54509002](#)
11. Колесниченко О.Ю., Мартынов А.В., Пулит В.В., Колесниченко Ю.Ю., Шакиров В.В., Варламов О.О., Минушкина Л.О., Сотник А.Ю., Жилина Т.Н., Дорофеев В.П., Смородин Г.Н., Жапаров М.К., Мазелис Л.С. Современный передовой уровень искусственного интеллекта для умной медицины. — *Ремедиум*. — 2019; 4: 36—43. [eLibrary ID: 37532436](#)
12. Кореневский Н.А., Аксенов В.В., Родионова С.Н., Гонтарев С.Н., Лазурина Л.П., Сафонов Р.И. Метод комплексной оценки уровня информативности классификационных признаков в условиях нечеткой структуры данных. — *Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение*. — 2022; 3: 80—96. [eLibrary ID: 49725204](#)

REFERENCES:

1. Kazarian G.G., Bekreev V.V., Ivanov S.Yu., Oborotistov N.Yu., Gu-sarov A.M., Khlystova T.V., Ivanova I.V., Soloshenkov P.P., Tsay P.A., Kibardin I.A. Possibilities of ultrasound diagnostics and the use of artificial neural network to assess the morphology and size of the articular disc of the temporomandibular joint. *Clinical Dentistry (Russia)*. 2024; 1: 54—59 (In Russian). [eLibrary ID: 63433208](#)
2. Muraev A.A., Guseynov N.A., Tsay P.A., Kibardin I.A., Burenchev D.V., Ivanov S.S., Oborotistov N.Yu., Matuta M.A., Grachev N.S., Larin S.S. Artificial neural networks in dental and maxillofacial radiology: a review. *Clinical Dentistry (Russia)*. 2020; 3 (95): 72—80 (In Russian). [eLibrary ID: 44008071](#)
3. Lin C., Huang Y., Wang W., Feng S., Feng S. Lesion detection of chest X-Ray based on scalable attention residual CNN. *Math Biosci Eng.* 2023; 20 (2): 1730—1749. [PMID: 36899506](#)
4. Yu G., Sun K., Xu C., Shi X.H., Wu C., Xie T., Meng R.Q., Meng X.H., Wang K.S., Xiao H.M., Deng H.W. Accurate recognition of colorectal cancer with semi-supervised deep learning on pathological images. *Nat Commun.* 2021; 12 (1): 6311. [PMID: 34728629](#)
5. Rogatskin D.V., Geletin P.N. Optimization of the algorithm for intraoral radiography of multi-rooted teeth on the example of the first maxillary molars and mandibular molars with radix entomolaris. Part 1. *Clinical Dentistry (Russia)*. 2023; 2: 16—23 (In Russian). [eLibrary ID: 54167521](#)
6. Levan'kov B.V., Vyborov E.M., Yakovenko N.I. Medical decision-making support system based on bayesian networks in medical diagnostics. *Russian Military Medical Academy Reports*. 2020; 4: 39—43 (In Russian). [eLibrary ID: 48033883](#)
7. Shanina A.I. The use of artificial intelligence in dentistry. *International Research Journal*. 2023; 6 (132): (In Russian). [eLibrary ID: 54052633](#)
8. Guefrechi S., Jabra M.B., Ammar A., Koubaa A., Hamam H. Deep learning based detection of COVID-19 from chest X-ray images. *Multimed Tools Appl.* 2021; 80 (21—23): 31803—31820. [PMID: 34305440](#)
9. Ranjbarzadeh R., Bagherian Kasgari A., Jafarzadeh Ghoushchi S., Anari S., Naseri M., Bendechache M. Brain tumor segmentation based on deep learning and an attention mechanism using MRI multi-modalities brain images. *Sci Rep.* 2021; 11 (1): 10930. [PMID: 34035406](#)
10. Rogatskin D.V., Geletin P.N. Optimization of the algorithm for intraoral radiography of multi-rooted teeth on the example of the first maxillary molars and mandibular molars with radix entomolaris. Part 2. *Clinical Dentistry (Russia)*. 2023; 3: 6—13 (In Russian). [eLibrary ID: 54509002](#)
11. Kolesnichenko O.Yu., Martynov A.V., Pulit V.V., Kolesnichenko Yu. Yu., Shakirov V.V., Varlamov O.O., Minushkina L.O., Sotnik A.Yu., Zhilina T.N., Dorofeev V.P., Smorodin G.N., Zhabarov M.K., Maze-lis L.S. Modern advanced artificial intelligence for smart medicine. *Remedium*. 2019; 4: 36—43 (In Russian). [eLibrary ID: 37532436](#)
12. Korenevsky N.A., Aksenov V.V., Rodionova S.N., Gontarev S.N., Lazurina L.P., Safronov R.I. Method of Complex Assessment of the Level of Information Content of Classification Features in the Conditions of Fuzzy Data Structure. *Proceedings of the Southwest State University. Series: IT Management, Computer Science, Computer Engineering. Medical Equipment Engineering*. 2022; 3: 80—96 (In Russian). [eLibrary ID: 49725204](#)