

УДК 617.741:616.741-077.21]:004.9

<https://doi.org/10.51523/2708-6011.2024-21-4-18>

Выбор современного метода обработки цифровых и текстовых данных в области медицины, в частности патологии хрусталика и афакии

В. Л. Красильникова¹, О. Н. Дудич¹, С. М. Гридюшко²

¹Институт повышения квалификации и переподготовки кадров здравоохранения
Белорусского государственного медицинского университета, г. Минск, Беларусь

²Гомельская областная специализированная клиническая больница, г. Гомель, Беларусь

Резюме

В статье приводятся основные данные о возможности использования искусственного интеллекта при хирургии катаракты. В основу анализа положено более 150 источников, опубликованных за последние 10 лет, относящихся к теме катарактальной хирургии и искусственного интеллекта в медицине, в частности хирургии афакии. Использованы научно-медицинские базы данных PubMed, Google Scholar, Springer и eLibrary.ru. Для углубленного изучения были отобраны 24 статьи.

Ключевые слова: искусственный интеллект, машинное обучение, нейронные сети, машина опорных векторов, катаракта, афакия, макула

Вклад авторов. Все авторы внесли существенный вклад в проведение поисково-аналитической работы и подготовку статьи, прочитали и одобрили финальную версию для публикации.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Источники финансирования. Исследование проведено без спонсорской поддержки.

Для цитирования: Красильникова ВЛ, Дудич ОН, Гридюшко СМ. Выбор современного метода обработки цифровых и текстовых данных в области медицины, в частности патологии хрусталика и афакии. Проблемы здоровья и экологии. 2024;21(4):167–174. DOI: <https://doi.org/10.51523/2708-6011.2024-21-4-18>

The choice of modern methods for processing digital and text data in the field of medicine, particularly in lens pathology and aphakia

Viktoria L. Krasilnikova¹, Oksana N. Dudich¹, Sergey M. Gridjushko²

¹Institute of Advanced Training and Retraining of Healthcare Personnel
Belarusian State Medical University, Minsk, Belarus

²Gomel Regional Specialized Clinical Hospital, Gomel, Belarus

Abstract

This article provides key data on potential use of artificial intelligence in cataract surgery. The analysis is based on more than 150 sources published over the last 10 years, related to cataract surgery and the use of artificial intelligence in medicine, particularly in the surgery of aphakia. Scientific and medical databases such as PubMed, Google Scholar, Springer, and eLibrary.ru were used. A total of 25 articles were selected for in-depth study.

Keywords: artificial intelligence, machine learning, neural networks, support vector machine, cataract, aphakia, macula

Author contributions. All authors made significant contributions to the research and analytical work and the preparation of the article, and have read and approved the final version for publication.

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

Funding. The study was conducted without sponsorship.

For citation: Krasilnikova VL, Dudich ON, Gridjushko SM. The choice of modern methods for processing digital and text data in the field of medicine, particularly in lens pathology and aphakia. Health and Ecology Issues. 2024;21(4):167–174. DOI: <https://doi.org/10.51523/2708-6011.2024-21-4-18>

Введение

Катаракта — наиболее часто встречающееся глазное заболевание, которое является одной из ведущих причин слабости зрения и слепоты в мире, важной медико-социальной проблемой в большинстве стран [1]. Катаракта существенно снижает трудоспособность и качество жизни. Единственным эффективным лечением катаракты является операция экстракции хрусталика, а современным стандартом коррекции афакии — имплантация интраокулярной линзы (ИОЛ). Афакия — это патологическое состояние глаза, которое характеризуется отсутствием хрусталика. Главной причиной приобретенной афакии являются хирургические операции, в частности экстракция катаракты.

В настоящее время методика определения оптической силы ИОЛ осуществляется с помощью встроенных калькуляторов расчета интраокулярных линз в офтальмологических бесконтактных биометрах. Метод оптической биометрии признан наиболее точным для проведения диагностических исследований и расчета интраокулярных линз, в том числе у пациентов с различными аномалиями рефракции [2].

Погрешность при расчетах ИОЛ напрямую коррелирует с погрешностью измерения основных параметров глаза: переднезадней оси, глубины передней камеры, кривизны роговицы [3].

Важнейшей анатомической характеристикой глазного яблока является его сагиттальный размер, который у миопического глаза больше, а у гиперметрического меньше, чем у эметропического, и коррелирует со степенью аметропии. У взрослых эметропов он колеблется по разным данным от 22,6 до 24,2 мм, что связано с изменчивостью преломляющей силы роговицы [4].

Определение величины отклонения зрительной и анатомической осей глаза является важным при выборе типа оптической силы ИОЛ. Отсутствие учета данного фактора в предоперационном периоде может привести к погрешностям, что в результате обусловит недостаточную эффективность операции.

Таким образом, при расчете ИОЛ необходимо руководствоваться не только данными биометрических параметров глаза, но и следует учитывать положение зрительных осей.

Разработка метода математического моделирования прогноза удовлетворенности пациентов при коррекции афакии с помощью ИОЛ позволит значительно улучшить и упростить прогнозирование рефракционного результата и выявить основные корреляционные связи между удовлетворенностью пациента результатом хирургической операции, выбором ИОЛ и анато-

мо-топографическими параметрами макулярной зоны глазного дна.

Цель исследования

Проанализировать возможности доступных систем искусственного интеллекта (ИИ) (по данным доступной литературы) для вычисления вероятности удовлетворения пациента достигнутым целевым результатом коррекции афакии и выбрать вариант ИИ для дальнейшего усовершенствования в рамках развития представлений об удовлетворенности пациентов результатом хирургического лечения.

Материалы и методы

Проведен анализ отечественных и зарубежных литературных источников по проблеме использования искусственного интеллекта в медицине, в частности в офтальмологической практике. Использовались научно-медицинские базы данных PubMed, Google Scholar, Springer и eLibrary.ru. Проведена оценка более 150 статей, опубликованных за последние 10 лет. Для более детального научного анализа отобраны 24 публикации.

Результаты и обсуждение

История развития ИИ

Искусственный интеллект — это отрасль информатики, целью которой является создание интеллектуальных машин. Термин «искусственный интеллект» был придуман Джоном Маккарти, который впервые организовал семинар в 1956 г. с целью доказать следующий постулат: «действовать исходя из предположения о том, что каждый аспект обучения или любая другая особенность интеллекта в принципе может быть так точно описана, что машина может имитировать эту работу мозга» [5, 7]. Эта так называемая мастерская Дартмута теперь считается местом рождения ИИ.

Ветвь ИИ, называемая «машинное обучение», создана Артуром Самуэлем в 1959 г., основное внимание в нем уделяется изучению интеллекта путем разработки алгоритмов, извлекающих обобщенные принципы из данных. Эти принципы представлены в виде математических моделей, которые содержат описательные правила данных. Таким образом, подходы машинного обучения формировали контраст по сравнению с другими автоматизированными подходами, которые требовали, чтобы описательные правила данных были определены специалистами в данной области, а затем реализованы в автоматизированной системе программистами.

Классический подход к машинному обучению требует, чтобы набор биомаркеров или призна-

ков был непосредственно измерен по имеющимся данным (например, глубина передней камеры, толщина хрусталика, диаметр роговицы и т. д., измеренные по данным эхобиометрии в 2D-редакторе). Затем на основе обучающего набора примеров признаков с известными метками классификатор учится распознавать правильную метку по вновь увиденным признакам. После того как было разработано несколько мощных классификаторов, эффективность таких классических моделей машинного обучения резко возросла. Данная модель машинного обучения в основном опирается на дискриминационную силу выбранных функций, которые лежат в основе работы классификатора. Таким образом, в классическом машинном обучении задача инженера заменяется задачей ручной разработки эффективных предметно-ориентированных функций (врача-консультанта) [6].

Основной задачей в исследованиях в области машинного обучения является имитация нейронной структуры центральной нервной системы человека путем создания искусственных нейронных сетей (ИНС), учитывая что мозг является единственным существующим рабочим примером высокоэффективного распознавания образов. Система ИНС — это вычислительная система, основанная на сети единиц, называемых искусственными нейронами, организованными в слои. Слои нейронов выполняют преобразования сигнала, когда он проходит от входного (первого) слоя к выходному (последнему) слою.

Ранние ИНС 90-х гг. быстро нашли свое применение в медицинских приложениях, поскольку они были признаны хорошими классификаторами, где, например, входными данными будет набор соответствующих характеристик пациента, а выходными данными будет диагноз. Было показано, что они способны на том же уровне, что и опытный клиницист, обнаруживать инфаркт миокарда у пациентов с грудной болью в отделении неотложной помощи [8]. Возможности ИНС распространялись от ультразвуковой диагностики рака почки до скрининга [9] диабетической ретинопатии на основе признаков, извлеченных из изображения глазного дна [10].

Эти ранние формы ИНС проигрывали другим статистическим методам обучения в течение определенного периода времени, однако с 2012 г. они приобрели новое «рождение», когда были разработаны новые ветви ИИ, основанные на глубоких нейронных сетях (DNN). DNN — это ИНС с несколькими промежуточными слоями, расположенными между входным и выходным слоями, что позволяет каждому уровню учиться преобразовывать свой входной сигнал в постепенно более абстрактное и более высокое представление уровня, используя меньше искусственных

нейронов, чем сопоставимый неглубокий ИНС, что делает их более эффективными в обучении. Ключевым преимуществом DNN является то, что их производительность постоянно улучшается с размером набора обучающих данных. Кроме того, существенный прогресс в вычислительной мощности неожиданно позволил таким DNN обучаться и применяться в разумные сроки. Таким образом, при наличии достаточного количества примеров данных и вычислительной мощности DNN легко превзошел классические методы машинного обучения в стандартных тестах ИИ. Эта эволюция открыла новые возможности искусственного интеллекта и машинного обучения под названием «глубокое обучение» [11]. Основная идея заключается в том, что нейронная сеть вместо того, чтобы просто выступать в качестве классификатора, также может служить в качестве экстрактора признаков. Следовательно, одна глубокая нейронная сеть выполняет обе задачи и может научиться совместно извлекать признаки, которые подходят для данной задачи классификации, и классифицировать их. Такие глубокие сети позволяют проводить обучение полностью от начала до конца, потому что вместо того, чтобы учиться распознавать выходную категорию по функциям, созданным вручную, они учатся распознавать ее непосредственно из входного сигнала. Таким образом, в глубоком обучении задача ручного инжиниринга предметно-ориентированных функций заменяется на разработку надежных глубоких нейронных архитектур.

Варианты ИИ

Можно рассмотреть следующие варианты ИИ:

1. Методы машинного обучения (ML), анализирующие структурированные данные, такие как изображения, генетические и EP-данные (о которых изложено выше).

2. Методы обработки естественного языка (Natural Language Processing, NLP), которые играют важную роль в анализе и извлечении информации из неструктурированных медицинских данных [12].

Методы обработки естественного языка включают:

- токенизацию — разбиение текста на отдельные слова или токены для дальнейшей обработки;
- лемматизацию и стемминг — приведение слов к их базовым формам (леммам) или усечение слов до их основы (стемминг) для уменьшения размерности и улучшения анализа;
- извлечение ключевых фраз и терминов — выделение наиболее важных слов или фраз, которые могут содержать информацию о диагнозах, симптомах, лечении и других меди-

цинских концепциях;

- синтаксический анализ — построение деревьев зависимостей или грамматических структур для понимания синтаксической структуры предложений и выделения важных отношений между словами;

- семантический анализ — анализ значения слов и фраз для понимания их контекста и смысла в конкретной медицинской области;

- извлечение информации — автоматическое извлечение структурированной информации из текста, такой как диагнозы, лечение, возраст и другие медицинские параметры;

- классификацию текста — определение категорий или тегирование текста для его последующей обработки и анализа;

- именованные сущности — распознавание и классификация именованных сущностей, таких как имена пациентов, медицинские термины, лекарственные препараты и т. д.

Эти методы могут быть применены в различных задачах, таких как извлечение информации из клинических записей, автоматическое заполнение электронных медицинских карт, анализ научных статей и медицинских журналов, а также для создания интеллектуальных систем поддержки принятия решений в медицине [1, 3].

Выбор конкретной модели ИИ зависит от специфики данных, целей задачи, объема доступных данных для обучения, а также от требуемой интерпретируемости модели. Также важно учитывать, что для построения эффективной модели может потребоваться тщательная предварительная обработка данных, включая нормализацию, обработку пропущенных значений и выбор значимых признаков.

Применение ИИ в медицине

В наши дни ИИ становится весьма популярным в здравоохранении, в том числе в офтальмологии.

Основные области применения ИИ в здравоохранении включают [1, 2]:

- диспансерное наблюдение и массовые осмотры;

- диагностическую визуализацию для анализа медицинских изображений;

- обработку и анализ лабораторных данных;

- электродиагностику для оценки электрической активности организма;

- генетическую диагностику и анализ генетической информации;

- использование клинических данных для прогнозирования и диагностики заболеваний;

- создание и анализ примечаний при эксплуатации медицинских устройств и оборудования;

- управление и обработку электронных ме-

дицинских карт для хранения и доступа к медицинской информации пациентов.

В рамках данного исследования рассмотрены возможности использования следующих вариантов ИИ:

1. Математические модели.

2. Рекуррентные нейронные сети.

Примеры использования ИИ в офтальмологии

Использование ИИ в офтальмологии можно показать на примере модели «скрытый Марков» [13, 14]. Статистические модели, такие как скрытые марковские модели (СММ), позволяют извлекать скрытую информацию из наблюдаемых последовательных атрибутов или символов. Названные в честь русского математика Андрея Андреевича Маркова, эти модели нашли применение в различных областях, включая распознавание речи, анализ биологических нуклеотидных последовательностей, предсказание экзонов и интронов в ДНК, идентификацию функциональных мотивов (доменов) в белках и выравнивание двух последовательностей. Эффективная модель СММ имитирует источник реального мира, преобразуя наблюдаемые данные в символы. Методы машинного обучения, основанные на СММ, успешно решают различные задачи, включая распознавание речи, оптическое распознавание символов, биоинформационные задачи, такие как генетический анализ, и проблемы вычислительной биологии. В рамках скрытых марковских моделей дискретный случайный процесс проходит через серию «скрытых» от наблюдателя состояний, генерируя выходные данные, которые представляют собой решение проблемы. Каждое скрытое состояние генерирует символ, представляющий элементарную единицу моделируемых данных. Это мощный метод, используемый в случаях, когда можно вычислить вероятность последовательности наблюдаемых событий. Некоторые интересующие события скрыты и не наблюдаются непосредственно. СММ позволяют нам говорить как о наблюдаемых, так и о скрытых событиях, что аналогично скрытым слоям в нейронных сетях. Первым шагом в построении СММ является создание матрицы вероятности перехода, представляющей вероятность перехода из одного состояния в другое [13, 14]. В рамках скрытых марковских моделей интересующие переменные и вычисления включают в себя последовательность наблюдений, взятых из словаря, и последовательность вероятностей наблюдения, называемую вероятностями выбросов. Каждая вероятность выброса выражает вероятность того, что наблюдение будет сгенерировано из данного состояния из начальных распределений вероят-

ностей по обоим состояниям. В частности, СММ первого порядка предполагает, что вероятность конкретного состояния зависит только от предыдущего состояния и не зависит от какого-либо другого состояния. Это позволяет моделировать простые зависимости между состояниями. Однако другие методы могут быть смоделированы для более сложных сценариев, где зависимости между состояниями более сложны.

Алгоритм искусственного интеллекта IDx-DR, предназначенный для анализа изображений сетчатки, полученных с помощью камеры Topcon NW400 и загруженных в «облако», стал первым медицинским устройством, одобренным Управлением по контролю за продуктами и лекарствами США для применения искусственного интеллекта в диагностике диабетической ретинопатии легкой степени у взрослых с диабетом в апреле 2018 г. [13, 14].

Кроме того, была разработана «суперформула» ИОЛ, представляющая собой трехмерную структуру, основанную на сходстве формул ИОЛ. Она была создана путем объединения современных формул, таких как Хоффер К., Холладей I, Холладей I с поправкой Коха, с формулой Хейгиса. Данная «суперформула» позволяет рассчитывать силу ИОЛ для всех типов глаз [18].

В настоящее время ведется активная разработка алгоритмов для диагностики экстремических состояний роговицы и глаукомы. Литман Т. и соавторы применили искусственные нейронные сети для диагностики глаукомы на основе полей зрения у 106 пациентов с глаукомой и 249 человек в контрольных группах и сообщили, что алгоритм превзошел глобальные индексы при высокой специфичности (90–95 %) [18].

Кроме того, Li F. и соавторы использовали алгоритм глубокого обучения для функциональной диагностики глаукомы на основе 4012 изображений отклонений шаблона и заявили о точности 87,60 % (чувствительность — 93,20 %, специфичность — 82,60 %) [19].

Оба этих исследования демонстрируют высокую эффективность алгоритмов искусственного интеллекта в диагностике глаукомы и других заболеваний глаз.

В настоящее время ведется активная разработка алгоритмов для диагностики глаукомы и прогнозирования ее прогрессирования. Yousefi S. et al. провели поперечное исследование 677 пациентов и 1146 человек из контрольной группы, используя методы обучения полей зрения без учителя для прогнозирования прогрессирования глаукомы с чувствительностью 87 % и специфичностью 96 % [20]. Было показано, что машинное обучение без учителя последовательно выявляло прогрессирование

глаукомы намного раньше, чем традиционные методы.

Кроме того, прогнозирование прогрессирования с использованием поля зрения Хамфри, даже алгоритма 24–2 с глубоким обучением, может быть сделано на пять с половиной лет раньше, чем традиционные методы [21]. Mardin S. et al. комбинировали изображения конфокального лазерного сканирующего офтальмоскопа с полями зрения с использованием классификатора машинного обучения, получив площадь под кривой (AUROC) 0,977 (чувствительность — 95 %, специфичность — 91 %) [22].

Преимущество искусственного интеллекта (ИИ) заключается в том, что он может использовать данные большого разнообразия и изменчивости для моделирования результатов и их прогнозирования. Даже генетические данные можно будет использовать для стратификации риска после завершения картирования [23, 24].

Выбор архитектуры ИИ для обеспечения прогноза удовлетворенности пациентов результатом коррекции афакии

Математические модели ИИ. Искусственный интеллект может быть представлен следующими математическими моделями:

1. Линейная регрессия — это метод моделирования линейной зависимости между одной или несколькими объясняющими переменными и зависимой переменной или скалярным откликом. Простая линейная регрессия исследует связь между зависимой переменной и одной объясняющей переменной, тогда как в множественной линейной регрессии рассматривается влияние более чем одной объясняющей переменной на зависимую переменную. В случае многомерной линейной регрессии несколько зависимых переменных могут быть прогнозированы с использованием различных объясняющих переменных, которые могут коррелировать между собой. Это уравнение можно использовать для прогнозирования в узком смысле статистики, и оно является одним из самых простых инструментов, используемых для построения функций или уравнений, объясняющих результаты или зависимую переменную на основе независимых переменных. Результат можно представить в виде уравнения:

$$\text{Зависимая переменная} = \text{Константа} + (\text{Наклон} \times \text{Независимая переменная}) + \text{Ошибка.}$$

«Константа» представляет собой значение зависимой переменной, когда все независимые переменные равны нулю, «Наклон» показывает, как изменяется зависимая переменная при изменении независимой переменной, а «Ошибка» от-

ражает разницу между реальными значениями и значениями, предсказанными моделью [1, 4]. Позволяет изучить любое количество независимых переменных, попытаться уменьшить ошибку.

2. Логистическая регрессия. Логистическая модель, или логит-модель, используется в случаях, когда зависимая переменная имеет биномиальное распределение, что означает, что она может принимать только два значения, например «да» или «нет», « пройден» или «не пройден», «жив» или «мертв», «здоров» или «болен». Логистическая модель прогнозирует вероятность того, что наблюдение относится к определенной категории (например, «да» или « пройден») на основе значений независимых переменных. Вероятности, предсказываемые логистической моделью, находятся в диапазоне от 0 до 1, и их сумма для каждого наблюдения равна 1. Это делает логистическую модель особенно полезной для моделирования бинарных и категориальных данных. Логистическая регрессия представляет собой статистическую модель, которая использует логистическую функцию для моделирования вероятности бинарной зависимой переменной. Логарифм шансов (логит) для зависимой переменной обычно выражается как линейная комбинация одной или нескольких независимых переменных или предсказателей [15].

Нейронная сеть как вариант ИИ. Нейронные сети являются мощным инструментом для распознавания и обработки шаблонов. Их архитектура действительно напоминает сеть нейронов или цепь нейронов, где каждый нейрон или узел обрабатывает информацию и передает ее дальше по сети. Нейронные сети состоят из искусственных нейронов, или узлов, которые объединены в слои: входной, скрытые и выходной.

Скрытые слои имеют веса, которые являются параметрами модели, присваиваемыми каждому связанному с узлом входному сигналу. Эти веса позволяют моделировать сложные математические функции, приспосабливаясь к данным. Положительные и отрицательные веса влияют на силу связи между нейронами: положительный вес усиливает связь (возбуждение), а отрицательный — ослабляет (торможение).

Входные данные, передаваемые через нейронную сеть, подвергаются линейной комбинации с весами, прикрепленными к скрытым слоям, после чего происходит активация функции активации. Это позволяет сети изучать сложные зависимости и распознавать шаблоны в данных.

Нейронные сети широко используются как инструменты для кластеризации и классификации данных. В кластеризации они могут помочь группировать немаркированные данные, определяя сходство между ними на основе входных ха-

рактеристик. Например, методы кластеризации, такие как самоорганизующиеся карты Кохонена, могут использовать нейронные сети для создания топологических карт, отображающих сходство между различными кластерами данных.

В классификации нейронные сети также играют важную роль. Они могут быть обучены на маркированных данных, чтобы выявлять закономерности и паттерны, которые помогут классифицировать новые, неизвестные данные. Примером может быть использование сверточных нейронных сетей для классификации изображений, где сеть обучается распознавать определенные признаки и объекты на изображениях [17].

Примерами общедоступных глубоких нейронных сетей, таких как сверточные нейронные сети, являются GoogleNet, AlexNet и VGGNet. Также можно использовать такое программное обеспечение, как Caffe и Tensorflow.

Таким образом, для построения прогноза лечения пациента на основе анализа количественных и качественных показателей можно рассмотреть несколько типов нейронных сетей в зависимости от конкретных требований задачи:

1. Многослойный перцептрон (MLP). Это классическая нейронная сеть прямого распространения, которая хорошо подходит для задач классификации и регрессии. Она может быть эффективна при прогнозировании результатов лечения на основе множества входных признаков.

2. Рекуррентные нейронные сети (RNN). Если имеется временная зависимость между данными или последовательностью событий, например, в случае анализа динамики заболевания или протекания лечения во времени, то RNN могут быть эффективными инструментами.

3. Глубокие нейронные сети (DNN). Если задача требует анализа сложных взаимосвязей между множеством признаков, глубокие нейронные сети с множеством слоев могут быть эффективны.

4. Гибридные модели. Можно использовать комбинацию различных типов нейронных сетей или добавить дополнительные компоненты, такие как attention-механизмы или автоэнкодеры, чтобы улучшить производительность модели [16].

Заключение

Искусственный интеллект представляет собой процесс применения вычислительных мощностей компьютерных систем для выполнения разнообразных задач. В последние годы ИИ, обладая потенциалом значительно улучшить качество медицинской помощи, активно внедряется в практику для обеспечения высокой точности диагностических процедур.

Применение искусственного интеллекта в здравоохранении обладает значительным потенциалом для улучшения качества медицинских услуг и оптимизации процессов диагностики и лечения. Тем не менее эффективность внедрения технологий ИИ в данной области в значительной степени зависит от доступности и качества медицинских данных. Высококачественные и хорошо структурированные данные являются основой для обучения алгоритмов машинного обучения и повышения их предсказательной способности.

Ключевыми аспектами, способствующими успешной интеграции ИИ в медицинскую практику, являются процессы сбора, хранения, подготовки и анализа данных. Необходимо разработать и внедрить стандарты, обеспечивающие унификацию клинической терминологии. Это позволит обеспечить совместимость и интероперабельность данных, что, в свою очередь, будет способствовать эффективному обмену информацией между различными информационными системами и платформами здравоохранения.

Также критически важно обеспечить соблюдение биоэтических норм и стандартов при об-

работке и использовании медицинских данных. Этические и правовые аспекты применения ИИ должны быть учтены на всех этапах — от первоначального сбора данных до их анализа и применения для клинических решений. Это включает в себя прозрачность процессов, информированное согласие пациентов, а также защиту конфиденциальности и персональных данных.

Таким образом, для реализации полного потенциала ИИ в здравоохранении необходим комплексный подход, включающий как технологические, так и этические аспекты, что позволит создать надежную и эффективную экосистему для применения инновационных решений в области медицины.

Для определения вероятности удовлетворения пациентов от хирургического устранения афакии и прогнозирования результата получения таргетной рефракции можно использовать математические модели прогноза, но наиболее актуальным представляется использование (создание) авторских программных средств на базе нейронных сетей.

Список литературы / References

- Петров С.Ю., Козлова И.В., Полева Р.П. Катаракта: современный взгляд на консервативные подходы к лечению. *Клиническая офтальмология*. 2019;19(4):206-210.
Petrov SY, Kozlova IV, Poleva RP. Cataract: a modern view on conservative approaches to treatment. *Clin Ophthalmol*. 2019;19(4):206-210. (In Russ.).
- Киселева Т.Н., Оганесян О.Г., Романова Л.И. и др. Оптическая биометрия глаза: принцип и диагностические возможности метода. *Российская педиатрическая офтальмология*. 2017;12(1):35-42.
DOI: <https://doi.org/10.18821/1993-1859-2017-12-1-35-42>
Kiseleva TN, Oganesyanyan OG, Romanova LI, et al. Optical biometry of the eye: principle and diagnostic capabilities of the method. *Russ Pediatr Ophthalmol*. 2017;12(1):35-42. (In Russ.).
DOI: <https://doi.org/10.18821/1993-1859-2017-12-1-35-42>
- Куликов А.Н., Кокарева Е.В., Котова Н.А. Сравнение результатов биометрии глаза при использовании различных приборов. *Тихоокеанский медицинский журнал*. 2017;2(68):53-54.
DOI: <https://doi.org/10.17238/PmJ16091175.2017.2.53-55>
Kulikov AN, Kokareva EV, Kotova NA. Comparison of eye biometry results using different instruments. *Pacific Med J*. 2017;2(68):53-54. (In Russ.).
- Маковкин Е.М. Клиническое значение величины отклонения зрительной оси глазного яблока от его анатомической оси. *Вестник ВолГМУ*. 2008;1(25):77-79.
Makovkin EM. Clinical significance of the deviation of the visual axis of the eyeball from its anatomical axis. *Vestn VolGМУ*. 2008;1(25):77-79. (In Russ.).
- Sidey-Gibbons JAM, Sidey-Gibbons CJ. Machine learning in medicine: a practical introduction. *BMC Med Res Methodol*. 2019;19(1):1-18.
DOI: <https://doi.org/10.1186/s12874-019-0681-4>
- Guidance for industry: Electronic source data in clinical investigations, 2013. [Electronic resource]. [accessed 2024 Sep 2]. Available from: https://rx-360.org/wp-content/uploads/2018/08/Guidance-Electronic-Source-Data-in-Clinical-Investigations_2013.pdf
- Murdoch TB, Detsky AS. The inevitable application of big data to health care. *JAMA*. 2013.
DOI: <https://doi.org/10.1001/jama.2013.393>
- Baxt WG. Use of an artificial neural network for the diagnosis of myocardial infarction. *Ann Intern Med*. 1991;115(11):843-848.
DOI: <https://doi.org/10.7326/0003-4819-115-11-843>
- Maclin PS, Dempsey J, Brooks J, Rand J. Using neural networks to diagnose cancer. *J Med Syst*. 1991;15(1):11-19.
DOI: <https://doi.org/10.1007/BF00993877>
- Gardner GG, Keating D, Williamson TH, Elliott AT. Automatic detection of diabetic retinopathy using an artificial neural network: a screening tool. *Br J Ophthalmol*. 1996;11:940-944.
DOI: <https://doi.org/10.1136/bjo.80.11.940>
- LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521:436-444.
DOI: <https://doi.org/10.1038/nature14539>
- Bali J, Kant A, editors. *Basics of Biostatistics: A Manual for the Medical Practitioners*. 1st ed. New Delhi: Jaypee Brothers Medical Publishers; 2017. 556 p.
- Parsian M, editor. *Data Algorithms*. Sebastopol, CA: O'Reilly Media, Inc.; 2015. 778 p.
- Ma Y, Guo G, editors. *Support Vector Machines Applications*. New York: Springer; 2014. 302 p.
- Patel V, Shortliffe E, Stefanelli M, Szolovits P, Berthold M, Bellazzi R, et al. The coming of age of artificial intelligence in medicine. *Artif Intell Med*. 2009;46:5-17.
DOI: <https://doi.org/10.1016/j.artmed.2008.07.017>
- Shahid N, Rappon T, Berta W. Applications of artificial neural networks in health care organizational decision-making: A scoping review. *PLoS One*. 2019;14(2):1-22.
DOI: <https://doi.org/10.1371/journal.pone.0212356>
- Ladas JG, Siddiqui AA, Devgan U, Jun AS. A 3-D 'Super Surface' combining modern intraocular lens formulas to generate a 'super formula' and maximize accuracy. *JAMA Ophthalmol*. 2015;133(12):1431-6.
DOI: <https://doi.org/10.1001/jamaophthalmol.2015.3832>

18. Lietman T, Eng J, Katz J, Quigley HA. Neural networks for visual field analysis: How do they compare with other algorithms. *J Glaucoma*. 1999;8:77-80.

19. Li F, Wang Z, Qu G, Song D, Yuan Y, Xu Y, et al. Automatic differentiation of glaucoma visual field from nonglaucoma visual field using deep convolutional neural network. *BMC Med Imaging*. 2018;35(18):1-7.

DOI: <https://doi.org/10.1186/s12880-018-0273-5>

20. Yousefi S, Kiwaki T, Zheng Y, Sugiura H, Asaoka R, Murata H, et al. Detection of longitudinal visual field progression in glaucoma using machine learning. *Am J Ophthalmol*. 2018;193:71-79.

DOI: <https://doi.org/10.1016/j.ajo.2018.06.007>

21. Wen JC, Lee CS, Keane PA, Xiao S, Rokem AS, Chen PP, et al. Forecasting future Humphrey visual fields using deep learning. *PLoS One*. 2019;14(2):1-14.

DOI: <https://doi.org/10.1371/journal.pone.0214875>

22. Mardin CY, Peters A, Horn F, Jünemann AG, Lausen B. Improving glaucoma diagnosis by the combination of perimetry and HRT measurements. *J Glaucoma*. 2006;15(4):299-305.

DOI: <https://doi.org/10.1097/01.ijg.0000212232.03664.ee>

23. Burdon KP, Mitchell P, Lee A, Healey PR, White AJ, Rochtchina E, et al. Association of open-angle glaucoma loci with incident glaucoma in the Blue Mountains eye study. *Am J Ophthalmol*. 2015;159:31-36.

DOI: <https://doi.org/10.1016/j.ajo.2014.09.020>

24. Bali J, Garg R, Bali R. Artificial intelligence (AI) in healthcare and biomedical research: Why a strong computational/ AI bioethics framework is required. *Indian J Ophthalmol*. 2019;67:3-6.

DOI: https://doi.org/10.4103/ij.o.IJO_1292_18

Информация об авторах / Information about authors

Красильникова Виктория Леонидовна, д.м.н., профессор, профессор кафедры офтальмологии, Институт повышения квалификации и переподготовки кадров здравоохранения УО «Белорусский государственный медицинский университет», Минск, Беларусь

ORCID: <https://orcid.org/0000-0002-5852-2616>

e-mail: Krasilnikova_vik@mail.ru

Дудич Оксана Николаевна, к.м.н., доцент, доцент кафедры офтальмологии, Институт повышения квалификации и переподготовки кадров здравоохранения УО «Белорусский государственный медицинский университет», Минск, Беларусь

ORCID: <https://orcid.org/0009-0004-6554-3230>

e-mail: Oksana_s20@mail.ru

Гридюшко Сергей Михайлович, врач-офтальмолог отделения микрохирургии глаза № 2, У «Гомельская областная специализированная клиническая больница», Гомель, Беларусь

ORCID: <https://orcid.org/0009-0002-9013-6616>

e-mail: Grd.sergey8@gmail.com

Viktoria L. Krasilnikova, Doctor of Medical Sciences, Professor, Professor at the Department of Ophthalmology, Institute of Advanced Training and Retraining of Healthcare Personnel, Belarusian State Medical University, Minsk, Belarus

ORCID: <https://orcid.org/0000-0002-5852-2616>

e-mail: Krasilnikova_vik@mail.ru

Oksana N. Dudich, Candidate of Medical Sciences, Associate Professor at the Department of Ophthalmology, Institute of Advanced Training and Retraining of Healthcare Personnel, Belarusian State Medical University, Minsk, Belarus

ORCID: <https://orcid.org/0009-0004-6554-3230>

e-mail: Oksana_s20@mail.ru

Sergey M. Gridjushko, Ophthalmologist at the Department of Eye Microsurgery No. 2, Gomel Regional Specialized Clinical Hospital, Gomel, Belarus

ORCID: <https://orcid.org/0009-0002-9013-6616>

e-mail: Grd.sergey8@gmail.com

Автор, ответственный за переписку / Corresponding author

Гридюшко Сергей Михайлович

e-mail: Grd.sergey8@gmail.com

Sergey M. Gridjushko

e-mail: Grd.sergey8@gmail.com

Поступила в редакцию / Received 09.09.2024

Поступила после рецензирования / Accepted 10.09.2024

Принята к публикации / Revised 13.12.2024