

ISSN 2782-3806
ISSN 2782-3814 (Online)
УДК 616.132-004.8

МАШИННОЕ ОБУЧЕНИЕ И ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В ПРОГНОЗИРОВАНИИ, ДИАГНОСТИКЕ И ЛЕЧЕНИИ ЗАБОЛЕВАНИЙ ГРУДНОЙ АОРТЫ (ОБЗОР ЛИТЕРАТУРЫ). ЧАСТЬ 1

Успенский В. Е., Сапранков В. Л., Мазин В. И., Филиппов А. А.,
Боярская Н. В., Малашичева А. Б., Моисеева О. М.

Федеральное государственное бюджетное учреждение «Национальный медицинский исследовательский центр имени В. А. Алмазова» Министерства здравоохранения Российской Федерации, Санкт-Петербург, Россия

Контактная информация:

Успенский Владимир Евгеньевич,
ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава
России,
ул. Акkuratова, д. 2, Санкт-Петербург, Россия,
197341.
E-mail: v.e.uspenskiy@gmail.com

Статья поступила в редакцию 05.04.2023
и принята к печати 20.04.2023.

РЕЗЮМЕ

Аневризма и расслоение грудной аорты, невзирая на относительно невысокую распространенность в сравнении с клапанными пороками и ишемической болезнью сердца, являются потенциально фатальными заболеваниями и представляют собой серьезные проблемы здравоохранения. Показания к хирургическому лечению большинства заболеваний грудной аорты устанавливаются преимущественно на основании максимального диаметра аорты в той или иной зоне. В качестве дополнительных факторов риска ассоциированных с аортой осложнений, влияющих на «ужесточение» показаний и снижение «порогового» значения диаметра аорты, рассматриваются врожденные дисплазии соединительной ткани, аномалии грудной аорты (например, коарктация аорты), семейный анамнез аневризм, расслоений аорты и внезапных смертей. Вместе с тем у определенной доли пациентов с аортопатиями расслоения и разрывы аорты развиваются при нормальном или близком к нормальному диаметру грудной аорты в том или ином отделе. На развитие заболеваний аорты и осложнений влияет множество факторов, и оценка вклада в этиологию и патогенез каждого из них непроста. Машинное обучение и математическое моделирование с использованием искусственного интеллекта — активно развивающееся направление компьютерных наук, которое находит применение и в медицине, в частности, в изучении, диагностике и лечении аневризм и расслоений грудной аорты. В статье рассмотрены современные методы анализа данных, прогнозирования развития аневризм и расслоений грудной аорты, планирования лечения заболеваний грудной аорты и предсказания осложнений с помощью машинного обучения и искусственного интеллекта.

Ключевые слова: аневризма грудной аорты, заболевания аорты, искусственный интеллект, компьютеры, распространенность, расслоение аорты, факторы риска.

Для цитирования: Успенский В.Е., Сапранков В.Л., Мазин В.И., Филиппов А.А., Боярская Н.В., Малашичева А.Б., Моисеева О.М. *Машинное обучение и искусственный интеллект в прогнозировании, диагностике и лечении заболеваний грудной аорты (обзор литературы). Часть 1. Российский журнал персонализированной медицины. 2023;3(3):118-131. DOI: 10.18705/2782-3806-2023-3-3-118-131.*

MACHINE LEARNING AND ARTIFICIAL INTELLIGENCE IN THE PREDICTION, DIAGNOSIS AND TREATMENT OF THORACIC AORTIC DISEASES (LITERATURE REVIEW). PART 1

Uspenskiy V. E., Saprankov V. L., Mazin V. I., Filippov A. A., Boyarskaya N. V., Malashicheva A. B., Moiseeva O. M.

Almazov National Medical Research Centre, Saint Petersburg, Russia

Corresponding author:

Uspenskiy Vladimir E.,
Almazov National Medical Research Centre,
Akkuratova str., 2, Saint Petersburg, Russia,
197341.
E-mail: v.e.uspenskiy@gmail.com

Received 05 April 2023; accepted 20 April 2023.

ABSTRACT

Despite their relatively low prevalence compared to cardiac valve lesions and coronary heart disease, thoracic aortic aneurysm and dissection are potentially fatal and represent serious public health problems. The indications for surgical treatment in most thoracic aortic diseases are predominantly based on the maximum aortic diameter in a particular area. Congenital connective tissue disorder, thoracic aortic anomalies (e.g., coarctation), family history of aneurysms, aortic dissections, and sudden deaths are considered as additional risk factors of aortic-related complications influencing the “stricter” indications and lowering the “threshold” aortic diameter. At the same time, a certain proportion of patients with aortic diseases develop aortic dissection and rupture in normal or near-normal thoracic aortic diameter in certain section. Many factors influence the development of aortic diseases and complications, and assessing the contribution to the aetiology and pathogenesis of each factor is difficult. Machine learning and mathematical modeling using artificial intelligence is an actively developing area of computer science, which also finds application in medicine, in particular in the study, diagnosis, and treatment of thoracic aortic aneurysms and dissections. This article discusses

modern methods of data analysis, prediction of thoracic aortic aneurysms and dissections, treatment planning in thoracic aortic diseases, and prediction of complications using machine learning and artificial intelligence.

Key words: aortic aneurysm, aortic diseases, aortic dissection, artificial intelligence, computers, prevalence, risk factors, thoracic.

For citation: Uspenskiy VE, Saprankov VL, Mazin VI, Filippov AA, Boyarskaya NV, Malashicheva AB, Moiseeva OM. Machine learning and artificial intelligence in the prediction, diagnosis and treatment of thoracic aortic diseases (literature review). Part 1. Russian Journal for Personalized Medicine. 2023;3(3):118-131. (In Russ.) DOI: 10.18705/2782-3806-2023-3-3-118-131.

Список сокращений: АК — аортальный клапан, ВА — восходящая аорта, ДАК — двустворчатый аортальный клапан, КТ — компьютерная томография, МРТ — магнитно-резонансная томография, ПЭТ — позитронно-эмиссионная томография, РКТА — рентгеновская компьютерно-томографическая ангиография, DICOM — Digital Imaging and Communications in Medicine (цифровая визуализация и коммуникации в медицине).

ВВЕДЕНИЕ

Распространенность аневризм грудной аорты в среднем составляет 5–10 случаев на 100 000 населения в год с тенденцией к дальнейшему росту. Такая прогрессия обусловлена ростом продолжительности жизни, а также распространением визуализирующих методов исследований с одновременным повышением их чувствительности и специфичности [1–3]. Зачастую естественной последовательностью развития несемейной несиндромной (спорадической) аортопатии является первоначальное формирование патологического расширения грудной аорты, которое постепенно прогрессирует. В определенный момент в стенке аорты возникает макроскопический дефект — происходит нарушение ее целостности в виде расслоения, интрамуральной гематомы, разрыва с кровотечением в прилегающую область, в большинстве случаев являющихся смертельными. Во многих случаях острый аортальный синдром развивается без какой-либо предшествующей симптоматики. При остром расслоении восходящей аорты (ВА) смертность без лечения составляет 1–2 % в течение каждого часа с момента манифестации острого аортального синдрома, а госпитальная летальность при консерва-

тивной терапии составляет 25–27 % [4, 5]. Главной целью лечения является предотвращение фатального исхода путем «открытого» хирургического протезирования либо транскатетерной изоляции аневризмы грудной аорты. Хирургическое лечение заболеваний грудной аорты отличается сложностью, травматичностью и высоким риском периоперационных осложнений, и в экстренной ситуации вмешательства при остром аортальном синдроме по сравнению с плановым хирургическим лечением эти рискикратно выше [6]. Таким образом, актуальным является поиск предикторов осложнений (расслоения, разрыва) аневризмы грудной аорты, раннее выявление и возможное устранение факторов, способствующих патологическому расширению аорты, совершенствование клапаносохраняющей, транскатетерной и гибридной хирургии грудной аорты, и для решения этих задач многообещающим представляется использование методов машинного обучения.

ЧАСТЬ 1. СБОР И ОБРАБОТКА БИМЕДИЦИНСКИХ ДАННЫХ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ И ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Предикторы аневризмы грудной аорты и ее осложнений

Этиология аневризмы грудной аорты характеризуется множеством предрасполагающих факторов, действующих в различных комбинациях. Основными этиологическими факторами аневризм грудной аорты и предикторами осложнений являются артериальная гипертензия, соединительнотканная дисплазия (синдром Марфана, Элерса-Данло, Лойе-

са-Дитца и др.), врожденные аномалии аортального клапана (АК), такие как двустворчатый (ДАК), многостворчатый или четырехстворчатый АК. К группе более редких причин заболеваний грудной аорты относятся атеросклероз, воспалительные и инфекционные процессы (например, при сифилитическом, грибковом или аутоиммунном поражении), посттравматические (включая ятрогенные) аневризмы и расслоения аорты [7–11]. Хотя сам по себе ДАК рассматривается как одно из состояний, ассоциированных с патологическим расширением грудной аорты, согласно рекомендациям по диагностике и лечению заболеваний грудной аорты Европейского кардиологического общества (ESC — European Society of Cardiology) 2014 года и Американского колледжа кардиологии (ACC — American College of Cardiology)/Американской ассоциации сердца (AHA — American Heart Association) 2022 года, в отсутствие дополнительных условий, повышающих риск расслоения и разрыва аорты (факторов риска), пороговые значения максимальных диаметров восходящей аорты для принятия решения о хирургическом вмешательстве одинаковы для пациентов с двустворчатым и трехстворчатым АК, то есть де-факто ДАК сам по себе не является фактором риска осложнений, ассоциированных с грудной аортой [12–14]. Основным признаком, влияющим на вероятность расслоения или разрыва грудной аорты и определяющим показания к хирургическому лечению, является максимальный диаметр грудной аорты. Так, согласно исследованиям группы из Йельского университета, больший диаметр грудной аорты ассоциирован с более высоким риском естественных осложнений (разрыва, расслоения аорты и последующих неблагоприятных событий) при отсутствии хирургического лечения [7, 15, 16]. Дополнительными факторами риска осложнений, снижающими пороговые для принятия решения об операции значения максимального диаметра аорты, являются семейный анамнез аневризм, расслоений аорты, внезапной смерти, личный анамнез расслоений любой артерии, скорость расширения аорты в интересующей зоне 3 и более мм за 1 год, неконтролируемая артериальная гипертензия, тяжелая аортальная и/или митральная регургитация, коарктация аорты [17–19]. Вместе с тем сам по себе диаметр грудной аорты не всегда линейно связан с риском ее расслоения и разрыва, и у многих пациентов с уже имеющимся расслоением ВА диаметр последней не превышает пороговых для принятия решения о хирургическом вмешательстве (55 мм для большинства пациентов). Так, в выборке из 591 пациента с острым расслоением ВА, включенных в исследование Международного регистра острых

расслоений аорты (IRAD — International Registry of Acute Aortic Dissection) в период между 1996 и 2005 гг., средний диаметр ВА составил 53 см — уже после развития расслоения. 349 (59 %) пациентов имели максимальный размер ВА менее 55 мм, у 229 (40 %) — диаметр ВА составил менее 50 мм, а около половины больных, имевших после расслоения диаметр ВА менее 40 мм, вовсе не имели общеизвестных факторов риска аортопатий (артериальная гипертензия, соединительнотканые дисплазии, ДАК) [20]. В ряде других исследований также было показано, что у 60–70 % пациентов с расслоением ВА уже после развития острого аортального синдрома максимальный диаметр аорты не превышал 50 мм, то есть до расслоения ее диаметр был существенно меньше, возможно, близко к нормальному [21–23]. Остается неясным «удельный вес» каждого фактора риска в процессе возникновения и прогрессирования аортопатии у отдельно взятого пациента вследствие большого числа потенциальных факторов риска и различного вклада каждого из них в каждом конкретном случае. Кроме того, существует вероятность наличия «неучтенных» факторов риска, на первый взгляд, не играющих значимую роль в возникновении аневризмы или расслоения аорты, но влияние которых на развитие аортопатии у определенного пациента может быть определяющим. Привлекательной целью, которая до сих пор в полной мере не реализована, является пациент-ориентированное прогнозирование развития аневризм, расслоений, разрывов грудной аорты и планирование лечения этой группы заболеваний с помощью методов машинного обучения, в том числе с использованием искусственного интеллекта.

Данные, которые мы собираем

Обязательным исходным этапом анализа информации является ее сбор для занесения в базу данных и последующего анализа. Применительно к заболеваниям грудной аорты данные, используемые в повседневной клинической практике, чаще всего представляют собой результаты визуализирующих исследований, характеризующих аортопатию: данные рентгеновской компьютерно-томографической ангиографии (РКТА), магнитно-резонансной томографии (МРТ), эхокардиографии (ЭхоКГ), позитронно-эмиссионной компьютерной томографии (ПЭТ-КТ) с введением того или иного радиофармпрепарата (табл. 1) [14]. Реже, в основном при исследованиях со специальными задачами, объектами анализа становятся уровни биомаркеров, результаты сложных инструментальных методов (например, фотоплетизмографии или вызванных двигательных потенциалов) [24, 25].

Таблица 1. Диагностическая эффективность методов визуализации аорты различной модальности (адаптировано из Isselbacher E. M. и др., 2022) [14]

Параметр	РКТА	МРТ	ТТ-ЭхоКГ	ЧП-ЭхоКГ	УЗИ
Доступность	+++	++	+++	++	+++
Мобильность	-	-	+++	+++	+++
Скорость получения изображений	+++	+	++	++	++
Пространственное разрешение	+++	++	++	+++	++
Временное разрешение	+	++	+++	+++	+++
Получение трехмерных данных	+++	++	+	+	+
Оценка ветвей дуги аорты	+++	+++	++	+	НП
Оценка функции клапанов и желудочков	+	++	+++	+++	НП

Примечания: МРТ — магнитно-резонансная томография; НП — неприменимо; РКТА — рентгеновская компьютерно-томографическая ангиография, ТТ-ЭхоКГ — трансторакальная эхокардиография; ЧП-ЭхоКГ — чреспищеводная эхокардиография; УЗИ — ультразвуковое исследование брюшной полости; +++ — отличный результат; ++ — хороший результат; + — плохой результат; - — невозможно.

В то время как результаты лабораторных исследований, как правило, представляют собой «простые» числовые показатели, собираемые продукты визуализации (медицинские изображения) зачастую имеют существенно более сложную структуру и сохраняются в формате DICOM — Digital Imaging and Communications in Medicine (цифровая визуализация и коммуникации в медицине). Стандарт DICOM относится к области медицинской информатики и обмену цифровой информацией между устройствами медицинской визуализации и другими системами [26]. Он был разработан с акцентом на диагностическую медицинскую визуализацию, применяемую в кардиологии, неврологии, онкологии, офтальмологии и смежных дисциплинах, а также с учетом методов лечения, основанных на получении изображений, включая такие, как интервенционная кардиология, ряд областей сердечно-сосудистой хирургии, нейрохирургия, рентгенотерапия. Этот стандарт используется преимущественно для хранения и передачи медицинских изображений, позволяя объединять в одну сеть устройства для медицинской визуализации (компьютерные томографы, аппараты для проведения ЭхоКГ, цифровые рентгеновские аппараты и ангиографы), серверы, рабочие станции, сетевое оборудование и системы архивирования и передачи изображений (PACS — Picture Archiving and Communication System) различных производителей. Вместе с тем стандарт DICOM может быть применим и к большим массивам информации,

не связанной с изображениями, которая используется в клинической, исследовательской, ветеринарной и других медицинских областях [27, 28].

Процесс обработки информации состоит из ее сбора, первичного процессинга данных (визуальных, числовых), занесения информации в базу данных и собственно проведения анализа. Возможна автоматизация сбора и внесения в базу данных как числовых значений, так и результатов визуализирующих исследований, например, при помощи систем компьютерного зрения [29, 30]. Естественно, наиболее точные («валидные») данные — те, которые требуют минимального человеческого участия в процессе сбора и внесения в базу данных. Общей тенденцией является стремление к минимизации зависимости от участия в этом процессе оператора-человека. Современные растущие базы данных медицинских изображений требуют новых инструментов обработки для структурирования большого объема данных и извлечения клинически значимой информации, и здесь весьма перспективным представляется использование различных алгоритмов машинного обучения, глубокого обучения и искусственного интеллекта.

Алгоритмы машинного обучения и искусственный интеллект

Машинное обучение представляет собой активно развивающееся направление, которое находит применение и в медицине, в частности, в изучении, диагностике и лечении аневризм и расслоений

грудной аорты. По сути, машинное обучение — это то, каким образом машина (программа, алгоритм) учится давать ответ и решать поставленную задачу на основании входящих данных. Четкого разграничения между машинным обучением и статистикой в контексте предсказательного моделирования нет. Статистика обычно больше сосредоточена на теории вероятностей и глубинной структуре модели, в то время как машинное обучение имеет тенденцию уделять больше внимания разработке эффективных алгоритмов, которые далее масштабируются для оптимизации предсказательной модели [31, 32]. Существует несколько вариантов машинного обучения: обучение с учителем (контролируемое обучение), обучение без учителя, частично контролируемое и обучение с подкреплением. В ситуации *обучения с учителем* входящие данные представляют собой маркированные образцы с набором признаков (*features*), используемых для создания модели. Например, модель, созданная на основе сведений о пациентах с сердечно-сосудистыми заболеваниями, на основании входящих данных, описывающих конкретного человека, может рассчитать вероятность наличия у него ишемической болезни сердца. При *обучении без учителя* входящие данные являются немаркированными образцами с наборами признаков. Цель *обучения без учителя* — создание модели, которая принимает эти наборы признаков (в составе немаркированных, то есть не подвергавшихся обработке образцов, как, скажем, исходные изображения аорты, полученные при РКТА, а не результаты измерений аорты, выполненные специалистом-рентгенологом и выраженные в числовой форме) и преобразует их в другие наборы либо в значения, которые могут использоваться для решения практических задач. При *частично контролируемом обучении* набор данных содержит как маркированные, так и немаркированные образцы, и последних обычно существенно больше. Цель этого алгоритма обучения такая же, как в случае алгоритма *обучения с учителем*. Существует представление, что использование множества немаркированных образцов поможет алгоритму найти лучшую модель за счет увеличения объема входящей информации об изучаемой проблеме. *Обучение с подкреплением* является частью области машинного обучения, когда машина «живет» в окружении и способна воспринимать состояние своего окружения как набор признаков. В зависимости от выполняемых машиной действий могут возникать различные эффекты, например, получение вознаграждения. Цель данного алгоритма — изучение функции (подобно модели при *обучении с учителем*), принимающей в качестве входящих

данных характеристики состояния и на выходе выдающей оптимальное действие в этом состоянии. Действие считается оптимальным, если оно максимизирует ожидаемое среднее вознаграждение. *Обучение с подкреплением* решает определенный тип проблем, где принятие решений происходит последовательно, а цель является долгосрочной, например, игры, робототехника, управление ресурсами или логистика [33, 34]. Ансамблем обозначается формирование предсказания за счет использования набора моделей [32].

Для предсказательного моделирования и статистического машинного обучения при решении биомедицинских задач могут использоваться различные алгоритмы: линейная и логистическая регрессия, классификация, кластеризация, деревья решений, случайные леса, метод ближайших соседей и нейронные сети [35]. *Простая линейная регрессия* (лат. *regressio* — обратное движение) представляет собой моделирование односторонней связи между величинами двух переменных — независимой (предиктор) и переменной отклика (исход). Разница между *корреляцией* и *регрессией* состоит в том, что если *корреляция* измеряет связи между переменными, то *регрессия* количественно оценивает природу этой связи. *Простая линейная регрессия* отыскивает оптимальную прямую, предсказывающую переменную исхода как функцию от предикторной переменной. *Линейная регрессия* используется для прогнозирования числовых значений на основе линейной зависимости между различными величинами. *Логистическая регрессия* представляет собой алгоритм контролируемого обучения, делающий прогнозы для категориальных переменных, таких как ответы на вопросы «да/нет» [36, 37]. *Классификация* заключается в присвоении категории (класса) каждому элементу. Например, при *классификации* медицинских изображений элементам могут быть присвоены следующие классы: обзорная рентгенография, мультиспиральная компьютерная томография без контрастирования и с введением контрастного вещества, МРТ, ПЭТ-КТ. В отличие от *классификации*, при *кластеризации* не задаются исходные критерии разделения элементов набора данных на классы, а весь набор данных делится на более или менее однородные области (*кластеры*), где имеется максимальное сосредоточение однородных данных. Этот метод часто применяется для анализа очень больших массивов данных, например, для поиска пациентов с определенными осложнениями среди всего массива заболевших [38, 39].

Для прогнозирования числовых значений (*регрессия*) и для *классификации* данных по категориям

могут использоваться *деревья решений*. Они используют ветвящуюся последовательность связанных решений (*бинарных классификаторов*), которые можно представить в виде древовидной диаграммы, и обучаются поискам закономерностей между переменными прогноза и исхода (рис. 1А). Алгоритм дерева анализирует признаки изучаемых образцов один за другим, а не как единое целое, и выносит решения по одному, по ходу «листьев» дерева. Одной из проблем дерева решений является его размер, особенно при решении сложных задач — из-за множества входящих признаков, образующих бинарные классификаторы (ветвления), дерево значительно увеличивается в размерах, а точность прогнозирования снижается. В такой ситуации несколько (бывает, что очень много) *деревьев решений* объединяются в *случайный лес*, когда входящие данные берутся случайным образом, а предсказание значения или категории (класса) осуществляется путем объединения результатов нескольких *деревьев решений* (рис. 1Б) [40, 41]. Бустинг (англ. *boost* — повышение, усиление) представляет собой общую методику создания ансамбля моделей за счет подгонки последовательности моделей путем предоставления большего веса записям с большими остатками для каждого последующего цикла. Вариантами этого алгоритма являются *adaboost*, градиентный бустинг и стохастический градиентный бустинг [32]. Принцип бустинга заключается в использовании нескольких алгоритмов машинного обучения, изначально имеющих невысокую мощность, с тем, чтобы на их основе выработать один, но существенно более точный метод обработки данных. Примером является построение ансамбля из

нескольких деревьев решений. Для этого используется контрольный набор данных с известными исходами. Первое дерево решений обрабатывает набор данных в случайном порядке, оцениваются ошибочные ветвления, веса которых изменяются при подборе критериев для обучения следующего дерева решений. В итоге каждое из последующих деревьев будет точнее обрабатывать данные, и вместе они станут обрабатывать данные с существенно более высокой точностью [42, 43].

Метод ближайших соседей (nearest neighbor learning) классифицирует объекты на основе их сходства, например, функции расстояния. Принцип данного метода заключается в нахождении заранее определенного количества обучающих образцов, наиболее близких по расстоянию к новой точке, по которым можно предсказать метку, то есть классифицировать исходно неизвестный объект. Количество образцов может быть константой (*k*), определяемой пользователем (*k*-nearest neighbor learning) (рис. 2А), либо меняться в зависимости от локальной плотности точек, находящихся в определяемом пользователем радиусе от исследуемого объекта (*radius-based neighbor learning*) (рис. 2Б). Расстояние может быть любой метрической мерой, и наиболее распространенным выбором является стандартное евклидово расстояние. *Метод ближайших соседей* непараметрический, вследствие чего он часто оказывается успешным при решении задач по классификации с крайне неравномерной границей принятия решений [44].

Обработка данных алгоритмом машины опорных векторов представляет собой решение задачи

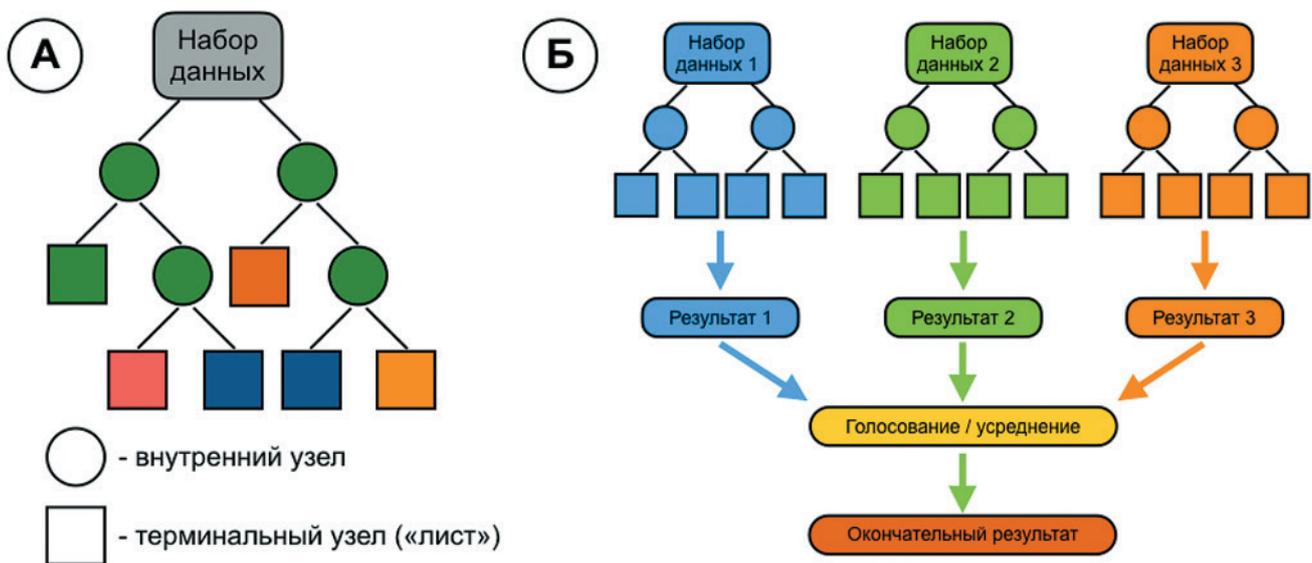


Рис. 1. Дерево решений (А) и случайный лес (Б) (адаптировано из Ali J. и др., 2012) [40]

классификации — найти гиперплоскость в N -мерном пространстве (N — количество признаков), которая однозначно классифицирует точки данных путем нахождения оптимальной линии разделения [45, 46]. Алгоритм машины опорных векторов может классифицировать как линейные, так и нелинейные данные. Сначала он отображает каждый элемент данных в N -мерное пространство признаков, затем он определяет гиперплоскость, которая разделяет элементы данных на два класса, максимизируя маргинальное расстояние для обоих классов и минимизируя ошибки классификации. Маргинальное расстояние для класса обозначает расстояние между гиперплоскостью принятия решения и ближайшим экземпляром, принадлежащим к этому классу. Цель — найти гиперплоскость, которая имеет мак-

симальное значение грани (margin), то есть максимальное расстояние между точками данных обоих классов (рис. 3) [33, 47].

Машинное обучение — подраздел искусственного интеллекта и компьютерных наук, направленный преимущественно на использование данных и алгоритмов для имитации способа обучения человека, постепенно повышая его точность. В течение нескольких последних десятилетий появилось несколько определений искусственного интеллекта. Один из основателей дисциплины и автор термина «искусственный интеллект» *John McCarthy* предложил следующее определение: «Искусственный интеллект — наука и инженерия создания интеллектуальных машин, в особенности — интеллектуальных компьютерных программ. Это связано с аналогич-

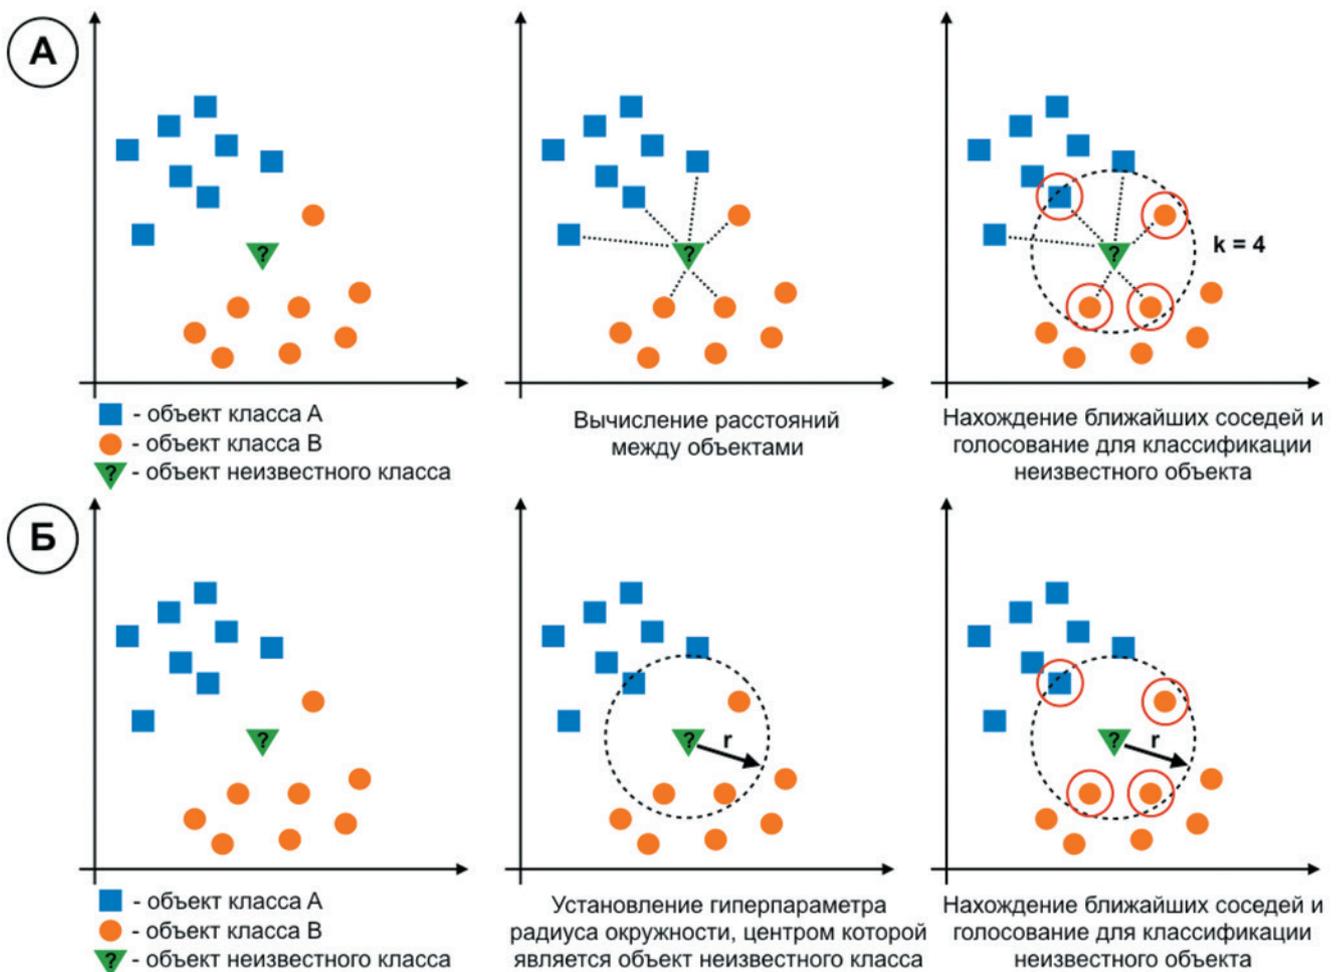


Рис. 2. Метод ближайшего соседа: k-nearest neighbor learning (A), radius-based neighbor learning (Б) (адаптировано из Taunk K. и др., 2019) [44]

Примечание: k — число образцов, определяемое пользователем, для принятия решения о классификации объекта неизвестного класса; r — радиус окружности, определяемый пользователем, для принятия решения о классификации объекта неизвестного класса.

ной задачей использования компьютеров для понимания человеческого интеллекта, но искусственный интеллект не обязан ограничиваться методами, которые поддаются биологическому наблюдению» [48]. В своей простейшей форме искусственный интеллект представляет собой область, объединяющую компьютерные науки и массивы данных для решения проблем. Исходно применение искусственного интеллекта было направлено на копирование процесса принятия решений человеком, и на начальных этапах извлечение и кодирование знаний человека отнимало много времени. Сегодня искусственный интеллект включает в себя такие подразделы, как машинное и глубокое обучение, которые часто упоминаются в сочетании с искусственным интеллектом. Эти дисциплины состоят из алгоритмов искусственного интеллекта, обычно прогнозирующих события или классифицирующих признаки на основе входящих данных [49]. Поскольку машинное и глубокое обучение обычно используются как взаимозаменяемые понятия, стоит обратить внимание на различия между ними, а также объяснить концепцию нейронных сетей. Нейронная сеть — математическая мо-

дель, построенная по принципу функционирования биологических нейронных сетей нервных клеток живого организма. Элементом нейронной сети является перцептрон (лат. *perceptio* — восприятие) — компьютерная модель восприятия информации мозгом, впервые предложенная Frank Rosenblatt в 1957 году [50]. По сути, перцептрон — алгоритм обучения с учителем, классифицирующий бинарные данные и состоящий из элементов трех типов: воспринимающих, ассоциативных и реагирующих, что позволяет создать набор ассоциаций между входящим стимулом и реакцией на выходе (рис. 4А). Нейронные сети за счет имитации работы человеческого мозга с огромным количеством связанных между собой узлов обработки хорошо распознают закономерности и играют важную роль в таких областях, как перевод на естественный язык, распознавание и создание изображений, распознавание речи. Машинное, глубокое обучение и нейронные сети — все они являются подразделами искусственного интеллекта, вместе с тем нейронные сети фактически являются подразделом машинного обучения, а глубокое обучение — подразделом нейронных сетей. Машинное и глубо-

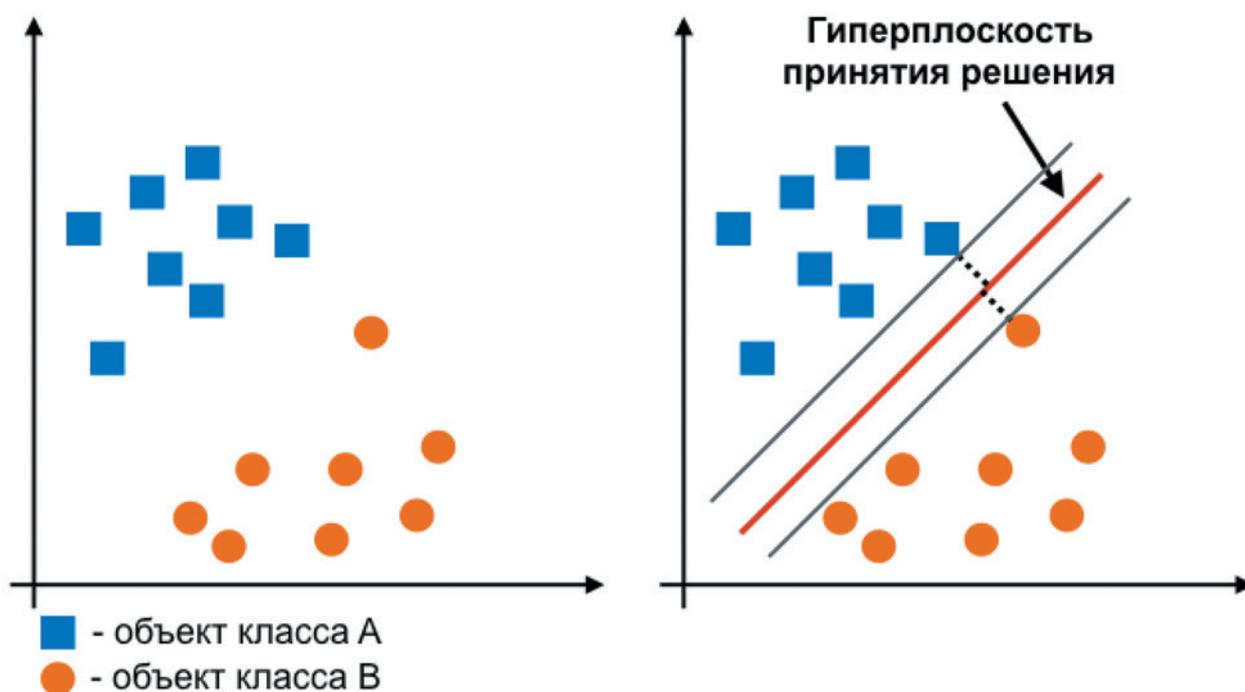


Рис. 3. Машина опорных векторов (адаптировано из Uddin S. и др., 2019) [33]

Примечание: Стрелкой обозначена гиперплоскость, разделяющая объекты разных классов. Пунктирными линиями обозначены маргинальные расстояния для классов — расстояния между гиперплоскостью принятия решения и ближайшими экземплярами, принадлежащими к определенному классу. Сплошными серыми линиями обозначена грань гиперплоскости (*margin*).

кое обучение различаются тем, как каждый алгоритм обучается. В случае классического («неглубокого») машинного обучения могут использоваться заранее маркированные экспертами из числа людей наборы данных (контролируемое обучение) с целью извлечения информации для своего алгоритма, а также наборы признаков для понимания различий между входящими данными, но это не всегда обязательно [33]. В ситуации глубокого обучения могут использоваться «сырые» неструктурированные данные (например, текст или изображения), и алгоритм автоматически определяет набор признаков, отличающих различные категории данных друг от друга. Это избавляет от необходимости вмешательства человека и позволяет использовать большие массивы данных. Глубокое обучение фактически состоит из нейронных сетей, в свою очередь, скомпонованных из узловых слоев, содержащих входной слой, одного или

несколько скрытых слоев и выходного слоя. Каждый узел (искусственный нейрон) соединяется с другим и обладает определенным весом и порогом чувствительности. Если выходной сигнал любого отдельного узла превышает заданное пороговое значение, этот узел активируется, передавая данные на следующий слой сети. В противном случае этот узел не передает данные на следующий уровень сети. Слово «глубокий» в отношении глубокого обучения означает количество слоев в нейронной сети. Сеть, состоящая более чем из трех слоев, включающих вход и выход, может считаться алгоритмом глубокого обучения или глубокой нейронной сетью, в то время как сеть, состоящая только из трех слоев, является обычной нейронной сетью [51]. Существует множество вариантов нейронных сетей. Так, многослойный перцептрон состоит из узлов, которые представляют собой числа: входное значение, выходное значение

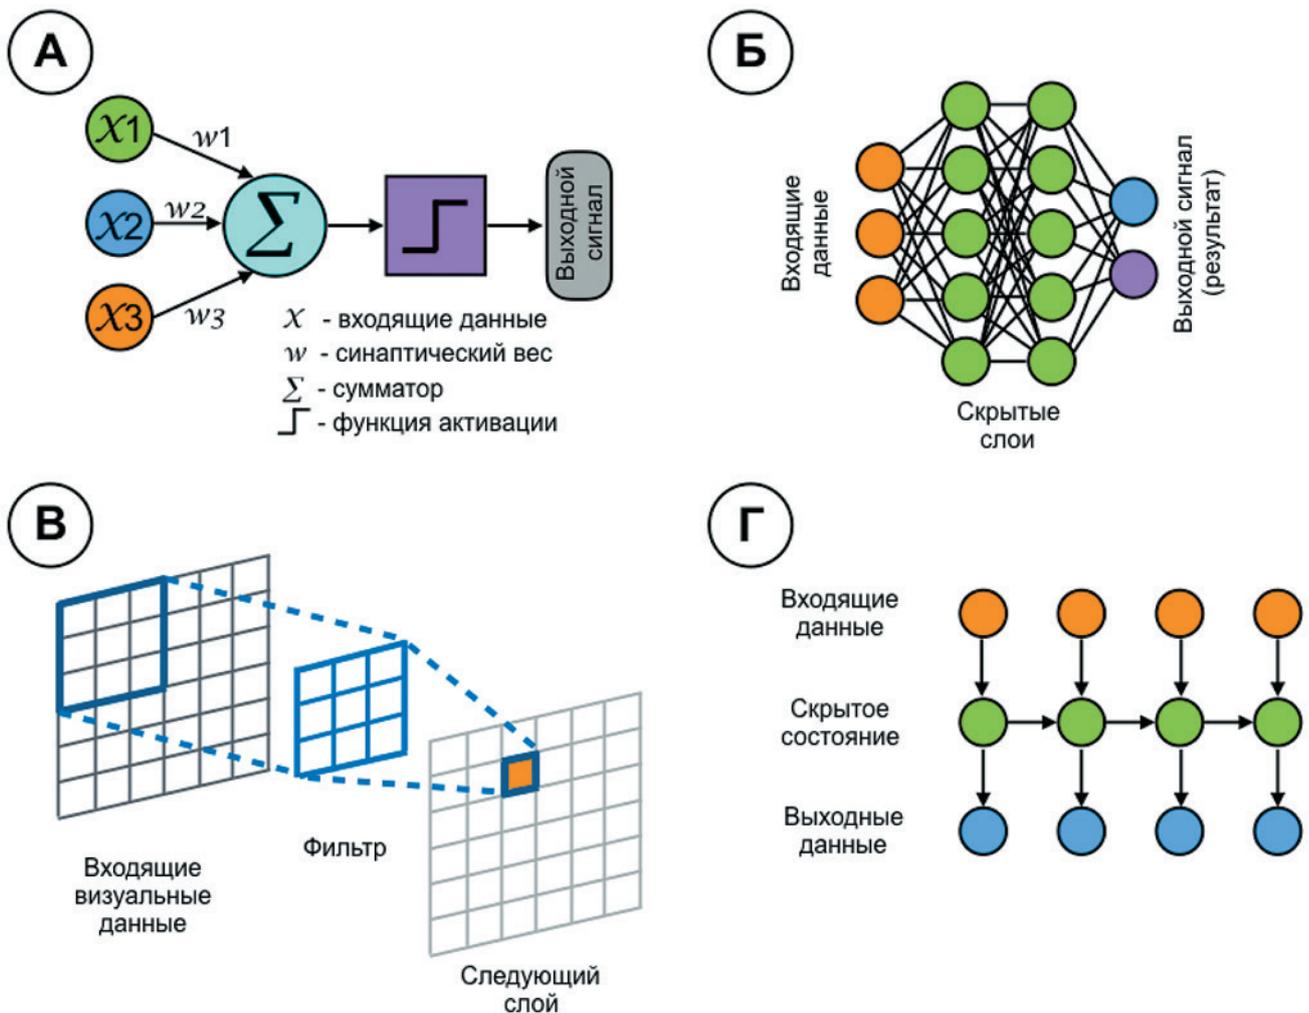


Рис. 4. Некоторые виды нейронных сетей: элементарный перцептрон (А), многослойный перцептрон (Б), сверточная нейронная сеть (В), рекуррентная нейронная сеть (Г) (адаптировано из Greener J. G. и др., 2022) [31]

или внутреннее (скрытое) значение. Узлы расположены по слоям, при этом между каждым узлом слоя и каждым узлом следующего слоя имеются связи, указывающие на изучаемые параметры (рис. 4Б). Разновидностью многослойного перцептрона с операцией свертки является сверточная нейронная сеть (convolutional neural network). В такой сети используются фильтры, которые перемещаются по входному слою и используются для вычисления значений в следующем слое. Сверточная нейронная сеть состоит из разных видов слоев: сверточных (convolutional), слоев субдискретизации (subsampling) и полносвязных слоев обычной нейронной сети (перцептрона) (рис. 4В). Операция свертки состоит из следующих этапов: скользящее окно (фильтр), имеющее размеры (x, x) , движется по входному признаку; результатами являются шаблоны размерами (x, x, d) , где d — глубина входного признака; каждый шаблон умножается на свое ядро свертки, в результате чего строится выходная карта признаков. Сверточные нейронные сети идеально подходят для анализа изображений, и лучшие результаты в этой области на сегодняшний день

получены с их помощью [52]. Рекуррентная нейронная сеть — наиболее сложный вид нейронных сетей с обратной связью. Такая сеть обрабатывает каждую часть последовательного входного сигнала, используя одни и те же выученные параметры, выдавая выход и обновленное скрытое состояние для каждого входа. Скрытое состояние используется для хранения информации о предыдущих частях последовательности (рис. 4Г) [31].

Общая схема использования различных методов машинного обучения приведена на рисунке 5. Естественно, все возможные варианты не могут быть здесь охвачены, например, количество точек данных, необходимых для того, чтобы машинное обучение стало применимым, зависит от числа признаков, доступных для каждой точки данных, причем для большего количества признаков требуется больше точек данных, а также количество точек данных связано с используемой моделью. Существуют модели глубокого обучения, которые работают с использованием немаркированных данных [31, 32].

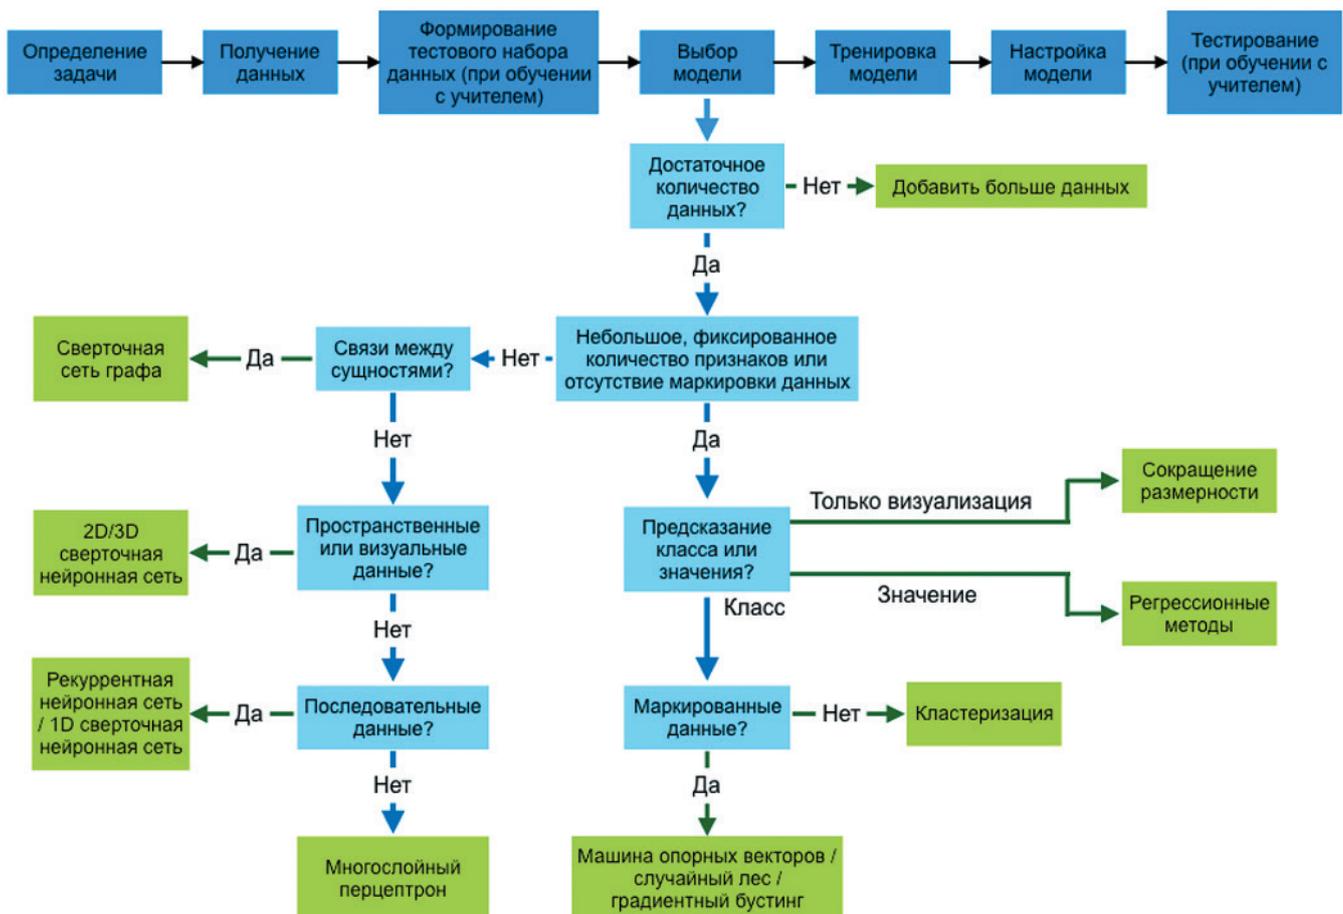


Рис. 5. Общий алгоритм использования методов машинного обучения (адаптировано из Greener J. G. и др., 2022) [31]

Конфликт интересов / Conflict of interest

Авторы заявили об отсутствии потенциального конфликта интересов. / The authors declare no conflict of interest.

Информация о соблюдении этических норм при проведении исследования

Исследование было выполнено в соответствии со стандартами надлежащей клинической практики (Good Clinical Practice) и принципами Хельсинкской декларации.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Olsson C, Thelin S, Stahle E, et al. Thoracic aortic aneurysm and dissection: increasing prevalence and improved outcomes reported in a nationwide population-based study of more than 14,000 cases from 1987 to 2002. *Circulation*. 2006;114(24):2611–8.
2. Elefteriades JA, Farkas EA. Thoracic aortic aneurysm clinically pertinent controversies and uncertainties. *Journal of the American College of Cardiology*. 2010;55(9):841–57.
3. Kuzmik GA, Sang AX, Elefteriades JA. Natural history of thoracic aortic aneurysms. *Journal of vascular surgery*. 2012;56(2):565–71.
4. Mussa FF, Horton JD, Moridzadeh R, et al. Acute aortic dissection and intramural hematoma: a systematic review. *Jama*. 2016;316(7):754–63.
5. Evangelista A, Isselbacher EM, Bossone E, et al. Insights from the International Registry of Acute Aortic Dissection: a 20-year experience of collaborative clinical research. *Circulation*. 2018;137(17):1846–60.
6. Ziganshin BA, Elefteriades JA. Treatment of thoracic aortic aneurysm: role of earlier intervention. *Seminars in thoracic and cardiovascular surgery*. 2015;27(2):135–43.
7. Elefteriades JA. Natural history of thoracic aortic aneurysms: indications for surgery, and surgical versus nonsurgical risks. *The Annals of thoracic surgery*. 2002;74(5):S1877–80; discussion S92–8.
8. Folkersen L, Wagsater D, Paloschi V, et al. Unraveling divergent gene expression profiles in bicuspid and tricuspid aortic valve patients with thoracic aortic dilatation: the ASAP study. *Molecular medicine (Cambridge, Mass)*. 2011;17(11–12):1365–73.
9. Kim S, Park JS, Yoo SM, et al. Traumatic aortic regurgitation combined with descending aortic pseudoaneurysm secondary to blunt chest trauma. *Cardiovascular journal of Africa*. 2014;25(5):e5–8.
10. Coady MA, Rizzo JA, Goldstein LJ, Elefteriades JA. Natural history, pathogenesis, and etiology of thoracic aortic aneurysms and dissections. *Cardiology clinics*. 1999;17(4):615–35; vii.
11. Roberts WC, Moore AJ, Roberts CS. Syphilitic aortitis: still a current common cause of aneurysm of the tubular portion of ascending aorta. *Cardiovascular pathology : the official journal of the Society for Cardiovascular Pathology*. 2019;46:107175.
12. Agnese V, Pasta S, Michelena HI, et al. Patterns of ascending aortic dilatation and predictors of surgical replacement of the aorta: A comparison of bicuspid and tricuspid aortic valve patients over eight years of follow-up. *J Mol Cell Cardiol*. 2019;135:31–9.
13. Erbel R, Aboyans V, Boileau C, et al. 2014 ESC Guidelines on the diagnosis and treatment of aortic diseases: Document covering acute and chronic aortic diseases of the thoracic and abdominal aorta of the adult. The Task Force for the Diagnosis and Treatment of Aortic Diseases of the European Society of Cardiology (ESC). *European heart journal*. 2014;35(41):2873–926.
14. Isselbacher EM, Preventza O, Hamilton Black J, 3rd, et al. 2022 ACC/AHA Guideline for the Diagnosis and Management of Aortic Disease: A Report of the American Heart Association/American College of Cardiology Joint Committee on Clinical Practice Guidelines. *Circulation*. 2022;146(24):e334–e482.
15. Elefteriades JA. Thoracic aortic aneurysm: reading the enemy's playbook. *The Yale journal of biology and medicine*. 2008;81(4):175–86.
16. Davies RR, Gallo A, Coady MA, et al. Novel measurement of relative aortic size predicts rupture of thoracic aortic aneurysms. *The Annals of thoracic surgery*. 2006;81(1):169–77.
17. Borger MA, Fedak PWM, Stephens EH, et al. The American Association for Thoracic Surgery consensus guidelines on bicuspid aortic valve-related aortopathy: full online-only version. *The Journal of thoracic and cardiovascular surgery*. 2018;156(2):e41–e74.
18. Kerneis C, Pasi N, Arangalage D, et al. Ascending aorta dilatation rates in patients with tricuspid and bicuspid aortic stenosis: the COFRASA/GENERAC study. *European heart journal cardiovascular Imaging*. 2018;19(7):792–9.
19. Oladokun D, Patterson BO, Sobocinski J, et al. Systematic review of the growth rates and influencing factors in thoracic aortic aneurysms. *European journal of vascular and endovascular surgery : the official journal of the European Society for Vascular Surgery*. 2016;51(5):674–81.
20. Pape LA, Tsai TT, Isselbacher EM, et al. Aortic diameter \geq 5.5 cm is not a good predictor of type A aortic dissection: observations from the International Registry of Acute Aortic Dissection (IRAD). *Circulation*. 2007;116(10):1120–7.
21. Juraszek A, Czerny M, Rylski B. Update in aortic dissection. *Trends in cardiovascular medicine*. 2022;32(7):456–61.

22. Sievers HH, Rylski B, Czerny M, et al. Aortic dissection reconsidered: type, entry site, malperfusion classification adding clarity and enabling outcome prediction. *Interactive cardiovascular and thoracic surgery*. 2020;30(3):451–7.
23. Rylski B, Schilling O, Czerny M. Acute aortic dissection: evidence, uncertainties, and future therapies. *European heart journal*. 2022.
24. Simon MV, Dong CC, Jacobs MJ, Mess WH. Neuromonitoring during descending aorta procedures. *Handbook of clinical neurology*. 2022;186:407–31.
25. Volynsky MA, Mamontov OV, Osipchuk AV, et al. Study of cerebrovascular reactivity to hypercapnia by imaging photoplethysmography to develop a method for intraoperative assessment of the brain functional reserve. *Biomedical optics express*. 2022;13(1):184–96.
26. Herrmann MD, Clunie DA, Fedorov A, et al. Implementing the DICOM standard for digital pathology. *Journal of pathology informatics*. 2018;9:37.
27. Wang KC, Kohli M, Carrino JA. Technology standards in imaging: a practical overview. *Journal of the American College of Radiology : JACR*. 2014;11(12 Pt B):1251–9.
28. DICOM reference guide. *Health devices*. 2001;30(1–2):5–30.
29. Lenchik L, Heacock L, Weaver AA, et al. Automated segmentation of tissues using CT and MRI: a systematic review. *Academic radiology*. 2019;26(12):1695–706.
30. Brown M, Browning P, Wahi-Anwar MW, et al. Integration of chest CT CAD into the clinical workflow and impact on radiologist efficiency. *Academic radiology*. 2019;26(5):626–31.
31. Greener JG, Kandathil SM, Moffat L, Jones DT. A guide to machine learning for biologists. *Nature reviews Molecular cell biology*. 2022;23(1):40–55.
32. Bruce P, Bruce A. *Practical statistics for data scientists. 50 Essential Concepts.*: O'Reilly Media, Inc.; 2017.
33. Uddin S, Khan A, Hossain ME, Moni MA. Comparing different supervised machine learning algorithms for disease prediction. *BMC medical informatics and decision making*. 2019;19(1):281.
34. Burkov A. *The hundred-page machine learning book: Andriy Burkov (January 13, 2019)*; 2019. 160 p.
35. Baştanlar Y, Ozuysal M. *Introduction to machine learning. Methods in molecular biology (Clifton, NJ)*. 2014;1107:105–28.
36. Zhao L, Chen Y, Schaffner DW. Comparison of logistic regression and linear regression in modeling percentage data. *Applied and environmental microbiology*. 2001;67(5):2129–35.
37. Tripepi G, Jager KJ, Stel VS, et al. How to deal with continuous and dichotomic outcomes in epidemiological research: linear and logistic regression analyses. *Nephron Clinical practice*. 2011;118(4):c399–406.
38. Henrard S, Speybroeck N, Hermans C. Classification and regression tree analysis vs. multivariable linear and logistic regression methods as statistical tools for studying haemophilia. *Haemophilia : the official journal of the World Federation of Hemophilia*. 2015;21(6):715–22.
39. Jain AK, Murty MN, Flynn PJ. Data clustering: a review. *ACM Computing Surveys*. 1999;31(3):264–323.
40. Ali J, Khan R, Ahmad N, Maqsood I. Random forests and decision trees. *International Journal of Computer Science Issues(IJCSI)*. 2012;9(5):272–8.
41. Nguyen JM, Jézéquel P, Gillois P, et al. Random forest of perfect trees: concept, performance, applications, and perspectives. *Bioinformatics (Oxford, England)*. 2021;37(15):2165–74.
42. Chen T, Guestrin C, editors. *Xgboost: A scalable tree boosting system. Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*; 2016.
43. Freund Y, Schapire RE, editors. *Game theory, on-line prediction and boosting. Proceedings of the ninth annual conference on Computational learning theory*; 1996.
44. Taunk K, De S, Verma S, Swetapadma A. A brief review of nearest neighbor algorithm for learning and classification. *2019 International Conference on Intelligent Computing and Control Systems (ICCS)*. 2019:1255–60.
45. Yan Y, Wang Y, Lei Y. Micro learning support vector machine for pattern classification: a high-speed algorithm. *Computational intelligence and neuroscience*. 2022;2022:4707637.
46. Bradley PS, Mangasarian OL. Massive data discrimination via linear support vector machines. *Optimization Methods and Software*. 2000;13(1):1–10.
47. Joachims T. *Making large-scale SVM learning practical. University of Dortmund Fachbereich Informatik*; 1998. Contract No.: LS-8 Report 24.
48. McCarthy J, Hayes PJ. Some philosophical problems from the standpoint of artificial intelligence. In: Michie D, editor. *Machine Intelligence. 2.1*: Elsevier; 1969. p. 463 ff.
49. Hicks SA, Strümke I, Thambawita V, et al. On evaluation metrics for medical applications of artificial intelligence. *Scientific reports*. 2022;12(1):5979.
50. Golubev YF. *Neural network methods in mechatronics. Moscow: Moscow State University Press*; 2007. 157 p. In Russian [Голубев ЮФ. Нейросетевые методы в мехатронике: М.: Изд-во Моск. ун-та; 2007. 157 с.].
51. Choi RY, Coyner AS, Kalpathy-Cramer J, et al. *Introduction to machine learning, neural networks, and deep learning. Translational vision science & technology*. 2020;9(2):14.

52. LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521(7553):436–44.

Информация об авторах:

Успенский Владимир Евгеньевич, д.м.н., заведующий НИЛ заболеваний аорты и аортального клапана Института сердца и сосудов ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава России;

Сапранков Валерий Леонидович, очный аспирант кафедры сердечно-сосудистой хирургии ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава России;

Мазин Виктор Игоревич, очный аспирант кафедры сердечно-сосудистой хирургии ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава России;

Филиппов Алексей Александрович, к.м.н., младший научный сотрудник НИЛ заболеваний аорты и аортального клапана ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава России;

Боярская Надежда Владимировна, младший научный сотрудник НИГ молекулярных механизмов кальцификации НЦМУ «Центр персонализированной медицины»;

Малашичева Анна Борисовна, д.б.н., заведующий НИЛ кардиологии и генетики ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава России;

Моисеева Ольга Михайловна, д.м.н., директор Института сердца и сосудов ФГБУ «НМИЦ им. В. А. Алмазова» Минздрава России.

Author information:

Uspenskiy Vladimir E., MD, PhD, Head of the Research Laboratory for Aorta and Aortic Valve Diseases, Institute of Heart and Vascular Diseases, Almazov National Medical Research Centre;

Saprankov Valery L., full-time postgraduate student of the Department of Cardiovascular Surgery, Almazov National Medical Research Centre;

Mazin Victor I., full-time postgraduate student of the Department of Cardiovascular Surgery at the Almazov National Medical Research Centre;

Filippov Alexey A., MD, Candidate of Medical Sciences, junior researcher, Research Laboratory for Aorta and Aortic Valve Diseases, Institute of Heart and Vascular Diseases, Almazov National Medical Research Centre;

Boyarskaya Nadezhda V., junior researcher, Research Group for Molecular Mechanisms of Calcification, World-Class Research Center for Personalized Medicine;

Malashicheva Anna B., MD, PhD, Head of Research Laboratory of Cardiology and Genetics, Almazov National Medical Research Centre;

Moiseeva Olga M., MD, PhD, Director of the Institute of Heart and Vascular Surgery, Almazov National Medical Research Centre.