

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ ОБРАЗОВАТЕЛЬНОЕ
УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«БАШКИРСКИЙ ГОСУДАРСТВЕННЫЙ МЕДИЦИНСКИЙ УНИВЕРСИТЕТ»
МИНИСТЕРСТВА ЗДРАВООХРАНЕНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
ИНСТИТУТ РАЗВИТИЯ ОБРАЗОВАНИЯ
КАФЕДРА МЕДИЦИНСКОЙ ФИЗИКИ И ИНФОРМАТИКИ



Мигунов Владимир Валерьевич

Выпускная квалификационная работа

ГЛУБИННОЕ ОБУЧЕНИЕ В ЗАДАЧЕ РАСПОЗНАВАНИЯ
НОВООБРАЗОВАНИЙ В ГОЛОВНОМ МОЗГЕ

Научный руководитель: д.ф.-м.н., профессор



А.А. Кудрейко

Специальность: 06.04.01 Биология

Профиль: современные информационные технологии
в медицине и биологии

Уфа – 2024

СОДЕРЖАНИЕ

ВВЕДЕНИЕ.....	3
ГЛАВА 1. МЕТОДЫ КЛАССИФИКАЦИИ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ.....	8
1.1. Нейронные сети.....	12
1.2. Логистическая регрессия.....	30
1.3. Метод К-ближайших соседей.....	31
1.4. Машина опорных векторов.....	33
1.5. Наивный Байес.....	35
1.6. Дерево решений.....	37
1.7. Случайный лес.....	39
1.8. Программная среда исследования Orange Data Mining.....	40
1.9. Выводы по главе 1.....	42
ГЛАВА 2. ИССЛЕДОВАТЕЛЬСКАЯ ЧАСТЬ. РАСПОЗНАВАНИЕ МРТ- ИЗОБРАЖЕНИЙ.....	43
2.1 Подготовка данных.....	43
2.2. Описание набора данных для исследования.....	46
2.3. Процесс обучения алгоритма.....	48
2.4. Прогностическая модель распознавания МРТ изображений.....	54
2.5. Полученные результаты и оценка модели.....	56
2.6. Выводы по главе 2.....	62
ЗАКЛЮЧЕНИЕ.....	64
СПИСОК ЛИТЕРАТУРЫ.....	66

Введение

Актуальность исследования. Проблема дифференциальной диагностики очаговых образований в головном мозге на протяжении многих лет остается актуальной [48] в силу агрессивности некоторых их видов. Такие новообразования представляют собой гетерогенную группу различных внутричерепных новообразований, доброкачественных или злокачественных, возникающих вследствие процесса неконтролируемого деления клеток, которые в прошлом являлись нормальными составляющими ткани мозга. Согласно данным по злокачественным новообразованиям, в Российской Федерации в 2020 году, доля злокачественных новообразований головного мозга составляла около 1,5% от общего числа [8]. Раннее диагностирование новообразований имеет важное значение для улучшения качества жизни пациентов. Основными методами исследования являются: магнитно-резонансная томография (МРТ) и компьютерная томография (КТ). Выявление онкологических процессов на ранних стадиях является сложной задачей из-за разнообразия анатомических форм опухолей, поэтому такие исследования, как правило, держат на контроле. В связи с этим, возникает задача распознавания новообразований на ранней стадии на основе диагностических изображений [60].

С каждым годом нарастает объем цифровых данных о пациентах, полученных с помощью различных методов диагностических исследований. Очевидно, возникает необходимость в реализации системы, позволяющей ускорить процесс обработки изображений. Разработка подобной системы автоматической сортировки МРТ-изображений является целью данной работы.

С другой стороны, внедрение искусственного интеллекта в обработке изображений поможет также снизить эмоциональное выгорание врачей [30].

Таким образом, целесообразно сформулировать алгоритмическое решение распознавания новообразований в головном мозге.

Обработка МРТ-изображений головного мозга возможна с помощью контролируемых методов обучения (обучение с учителем), например, искусственные нейронные сети, машины опорных векторов. Другой подход к обработке таких изображений - это неконтролируемые методы обучения (обучение без учителя), такие, например, как карта самоорганизации (self-organizing map), метод k-средних в сочетании с методами извлечения признаков. Другие методы контролируемой классификации (например, k-ближайших соседей) группируют пиксели изображения на основе их сходства по какому-либо признаку.

Выявление опухолей головного мозга и оценка продолжительности их существования после обнаружения опухоли представляет собой сложную задачу. На этапе установления диагноза проводится распознавание и классификация опухолей. Сложность этой задачи заключается в асимметричной форме новообразований, в разнообразии их фактуры, расположения и расплывчатых границ. Сегментация новообразований на снимках, полученных с помощью магнитно-резонансной томографии позволяет получить количественные измерения новообразований, а также информацию об их местоположении, что может быть полезным для корректировки лечения пациентов с данной патологией, а также помочь при планировании лечения. Выявление морфологических изменений в органе на начальной стадии позволяет врачу определить наиболее подходящий метод лечения. Весь этот набор данных, взятый из диагностических исследований, впоследствии обрабатывается в том числе с помощью методов глубокого машинного обучения. Машинное обучение эффективно выполняет сегментацию, классификацию и извлечение признаков для последующей классификации полученных цифровых изображений. Компьютерное зрение является приложением машинного обучения и искусственного интеллекта, которое извлекает данные из цифровых фотографий и видео, а затем

использует эти данные для вынесения значимых для пользователя суждений. Компьютерное зрение в настоящее время является наиболее востребованным в научном сообществе направлением машинного обучения. Достижения последних лет в этой области компьютерных наук продемонстрировали прорывные изменения, в результате чего алгоритмы машинного обучения превзошли возможности человека. Так, нейронная сеть, например, способна классифицировать изображения, ошибаясь в 1,2% случаев [42], тогда как ошибка человека составляет 5,1% [43]. Сегодня анализ медицинских изображений - это широкое поле для инноваций в области медицинской визуализации, возможности которого реализуются путем использования медицинского компьютерного зрения с целью выявления патологий и прогноза течения заболевания. Исследователи активно разрабатывают алгоритмы на основе машинного обучения, в том числе по анализу изображений со злокачественными новообразованиями [22].

В соответствии с утверждёнными указом Президента РФ № 203 от 9 мая 2017 года Стратегией развития информационного общества и указом № 490 от 10 октября 2019 года Национальной стратегией развития искусственного интеллекта на период до 2030 года, эта область рассматривается как приоритетная для обеспечения национальных интересов Российской Федерации.

Представленная выпускная квалификационная работа реализует компетенции магистерской программы “Современные информационные технологии в медицине и биологии” в части универсальных компетенций (УК-4, способность применять современные коммуникативные технологии для академического и профессионального взаимодействия), общепрофессиональных компетенций (ОПК-6, способность творчески применять и модифицировать современные компьютерные технологии, работать с профессиональными базами данных) и профессиональных компетенций (ПК-3, способность использовать современную аппаратуру и

вычислительные комплексы в соответствии с направленностью программы магистратуры).

По материалам работы автором была опубликована статья на XIII Международной научно-практической конференции «Актуальные аспекты развития науки и общества в эпоху цифровой трансформации» [9].

Целью работы является применение и адаптация алгоритмов машинного обучения для выявления патологий в МРТ-изображениях головного мозга.

Объектом исследования являются цифровые контрастные МРТ-изображения головного мозга.

В ходе выполнения работы были решены следующие **задачи**:

- поиск и формирование выборок МРТ-изображений;
- аналитический обзор существующих алгоритмов и систем распознавания объектов;
- разработка алгоритма обнаружения патологий головного мозга и выявления признаков наличия злокачественных новообразований;
- тестирование разработанной программной системы.

Достижение цели исследования реализовано при помощи программы интеллектуального анализа данных Orange Data Mining.

Практическая значимость работы заключается в том, что разработанная программа и база данных изображений могут применяться в учебном процессе для помощи студентам при освоении материала о глубинном обучении. Разработанная модель подходит для разных типов ЭВМ и может быть использована для анализа и обработки изображений в широком спектре предметных областей.

Достоверность полученных результатов и выводов обеспечивается корректным применением математического аппарата и методов математического моделирования; результатами натурального эксперимента;

согласованностью результатов вычислительных экспериментов на модельных примерах и реальных данных.

Основные положения, выносимые на защиту ВКР

1. Представляемая в ВКР модель глубинного обучения и диагностики новообразований в головном мозге относится к категории систем искусственного интеллекта.
2. Метод классификации изображений рентгеновских снимков и его сегментов, построенный на основе комплекса алгоритмов, реализующих процедуры морфологической фильтрации, сегментации, модификации границ сегментов и их классификации обеспечивает диагностическую эффективность по классам рентгенограмм головного мозга от 76 до 92%, а по классу сегментов “норма” – 94%.
3. Совокупность научно обоснованных технических и технологических решений, разработанных в рамках данной ВКР, имеет потенциал для повышения уровня оказания медицинской помощи населению.

Глава 1.

Методы классификации медицинских изображений

Основу данных, используемых в данной работе, составляют цифровые МРТ-изображения и формирование подобного изображения производится с помощью цифровой техники. Как и любое измерительное оборудование, в процессе работы она имеет определённые погрешности. Полученное в итоге изображение является суммой полезного сигнала и шума. Математически цифровое изображение представляет собой двумерную дискретную последовательность y_{ij} , которая состоит из суммы исходного незашумлённого изображения f_{ij} и шумовой составляющей η_{ij} : $y_{ij} = f_{ij} + \eta_{ij}$. Шумовая составляющая содержит значения яркости дефектов. Повышение качества цифрового изображения – важнейшая задача цифровой обработки изображений, её необходимо решить для улучшения визуального восприятия цифрового изображения и для последующего анализа отфильтрованных изображений. Сохранение границ контрастных объектов является важным фактом для алгоритмов обработки изображений. Задача анализа изображения актуальна во многих областях науки, таких как машинное зрение, медицина, робототехника и многих других. Очень часто подобные задачи не могут быть корректно решены, если изображение зашумлено, например, при сжатии и кодировании изображений.

Среди задач компьютерного зрения, задача классификации изображений является важнейшей. Она предполагает присвоение метки или тега всему изображению на основе ранее обработанных обучающих данных уже помеченных изображений. Для маркировки данных на этапе обучения часто используются общедоступные большие наборы данных. Необходимо также убедиться, что маркировка данных на этапе обучения выполнена точно, чтобы избежать возможных ошибок в работе модели. Само изображение анализируется на уровне составляющих его пикселей для определения наиболее подходящей метки для всего изображения (см. Рис. 1).

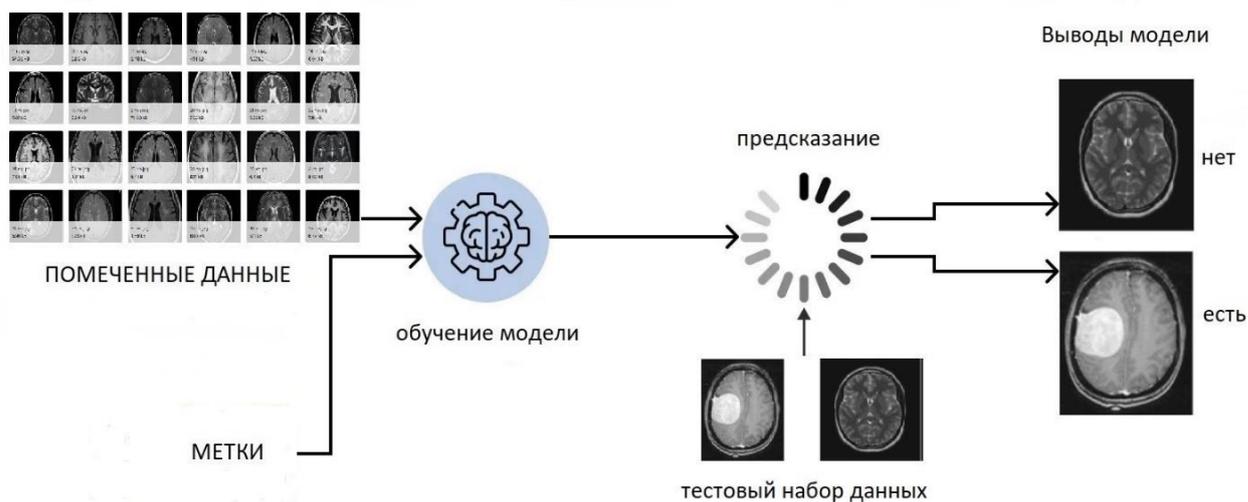


Рис. 1. Схема работы модели классификации изображений.

Видимое человеком изображение состоит из очень большого числа пикселей. Методы классификации, рассматривая изображение как массив матриц, размер которых определяется разрешением изображения, группируют пиксели в так называемые “классы”. Процесс классификации различается в зависимости от выбранного исследователем алгоритма.

В середине 80-х годов XX века Д. Марр предложил модульную парадигму обработки изображений [13], согласно которой обработка должна выполняться в несколько этапов для перехода от неструктурированной информации (то есть, растровых изображений) к их структурированной форме. Этот принцип применяется по настоящее время. Согласно парадигме Марра, в области машинного зрения выделяются следующие основные этапы обработки видеоданных:

1. Этап предварительной обработки изображений (удаление шумов, стабилизация их яркости и освещённости).
2. Сегментация, то есть выделение значимых для исследования объектов.
3. Выделение морфологии и геометрической структуры графических объектов.

На этапе предварительной обработки данных реализуются методы для улучшения качества данных изображения и подготовки их к последующим этапам. Ниже приведены несколько примеров того, что может быть включено в этап обработки изображений:

Изменение размера изображения меняет его ширину и высоту. Размер изображений часто изменяется до стандартного размера, чтобы сделать их вычислительно менее сложными для дальнейшей обработки.

Обрезка изображения. Если в изображении есть малоинформативные части, которые могут повлиять на производительность модели (например, фон или границы), предпочтительно обрезать изображение и оставить только необходимые части.

Нормализация изображения используется для приведения значений пикселей изображения к стандартному распределению. Оно включает в себя вычитание среднего значения и деление его на стандартное отклонение значений пикселей, изменение масштаба значений пикселей до фиксированного диапазона или использование методов выравнивания гистограммы для настройки параметров изображения (например, яркости или контрастности), чтобы сделать его более подходящим для анализа.

Снижение шума. Как было сказано выше, цифровые изображения часто содержат шум, который может повлиять на точность и производительность модели. Для подавления шума требуются такие методы фильтрации изображений, как фильтрация по Гауссу или медианная фильтрация. Такие методы уменьшают шум за счет сглаживания или размытия изображения, сохраняя при этом его края и детали.

Увеличение данных. Увеличение данных - это процесс создания новых вариантов изображений путем создания преобразований изображений, таких как вращение, масштабирование, переворачивание и изменение яркости и контрастности. Целью увеличения данных является диверсификация набора обучающих данных и увеличение его размера, что помогает повысить точность и надежность вашей модели классификации изображений.

На этапе сегментации происходит извлечение признаков изображений. Здесь происходит идентификация визуальных закономерностей изображения (контрастность, яркость, спектральные характеристики), которые будут использоваться для различения одного объекта от другого. Как только алгоритм усвоит эти особенности изображения и распознает их в обучающих данных, он сможет использовать их для классификации новых изображений. В цифровых методах визуальной диагностики (КТ, МРТ и др.) используется большое количество методов сегментации, которые подробно описаны в научной литературе [1].

На завершающем этапе (в процессе выделения морфологии графических объектов и их геометрической структуры) происходит отнесение изображения к определенному классу, то есть решение задачи классификации. Классификация изображений производится с помощью методов классификации данных, которые обобщенно можно представить с помощью четырех групп:

1. Классификаторы, основанные на таблице частот. Примерами данного типа классификаторов являются алгоритм дерево решений (*англ.* decision tree) – алгоритм, который разбивает набор данных на все меньшие и меньшие фрагменты, тем самым формируется дерево, и классификатор случайный лес (*англ.* random forest), состоящий из нескольких деревьев решений. Наивный Байесовский (*англ.* naïve Bayesian) алгоритм также относится в эту категорию.
2. Классификаторы, основанные на ковариационной матрице, например, логистическая регрессия (*англ.* logistic regression).
3. Классификатор, основанный на функции сходства, например, метод ближайших соседей (*англ.* k-nearest neighbours, KNN).
4. Прочие типы классификаторов: нейронные сети (*англ.* neural network) или машина опорных векторов (*англ.* support vector machine, SVM).

Все вышеперечисленные классификаторы данных применяются в анализе медицинских изображений. В данной работе мы также воспользуемся ими, поэтому разделы 1.1 – 1.7 будут посвящены их описанию.

1.1. Нейронные сети

Нейронная сеть представляет собой структуру, состоящую из искусственных нейронов, связанных друг с другом определённым образом и внешней средой с помощью связей, каждая из которых имеет определённый коэффициент (весовые коэффициенты $w_i > 0$). Веса w_i обычно инициализируются случайным образом перед обучением сети с использованием так называемой инициализации. Подобно биологическим нейронным сетям, искусственные нейросети состоят из набора вычислительных единиц, называемых нейронами (также известными как узлы). Структура искусственного нейрона (программного модуля) представлена на Рис. 2.

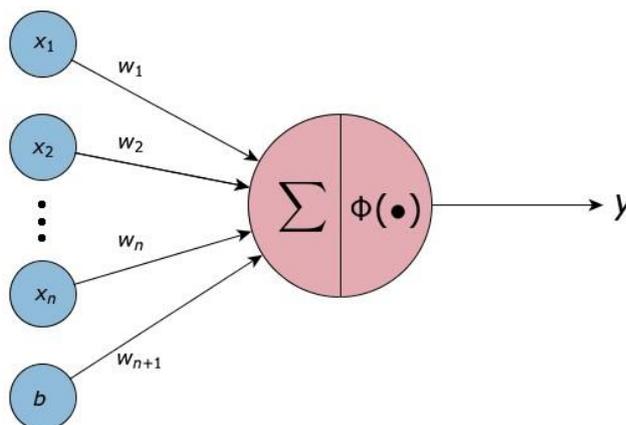


Рис. 2. Структура искусственного нейрона.

Нейрон вычисляет скалярное произведение между входными сигналами $X = [x_1, x_2, x_3, \dots, x_n]$ и соответствующими весовыми коэффициентами $W = [w_1, w_2, w_3, \dots, w_n]$ следующим образом: $S = X * W$, или

$$S = \sum_{i=1}^n x_i w_i . \quad (1.1)$$

К взвешенной сумме часто добавляется дополнительная постоянная смещения b (*англ.* bias, смещение) для придания модели большей гибкости.

$$S = \sum_{i=1}^n x_i w_i + b . \quad (1.2)$$

Затем это значение передается в функцию активации Y (см. Рис. 2), которая вычисляет выходной сигнал. Это основная концепция искусственного нейрона.

Фактически, нейронные сети - это группа нейронов, сложенных слоями. Они содержат входной слой, один или несколько скрытых слоев и выходной слой. Если нейронная сеть содержит более чем один скрытый слой, то она называется глубокой нейронной сетью (Рис. 3). Искусственные нейроны в таких сетях связаны друг с другом. В этих связях важен вес, так как узлы с более высокими значениями веса w_i имеют большее влияние на другие узлы[16].

Основа нейросети состоит из трёх слоёв взаимосвязанных нейронов: входной, скрытый и выходной. Сигналы поступают в нейросеть через входной слой, который обрабатывает данные и передаёт их дальше. Скрытые слои получают информацию от входного слоя или других скрытых слоёв. Глубина нейросети определяется количеством слоёв. Нейронные сети могут иметь много скрытых слоёв, каждый из которых анализирует данные, обрабатывает их и передаёт дальше. Скрытые слои нейронных сетей выполняют различные математические операции, такие как, суммирование и фильтрация, именно они позволяют извлекать необходимые признаки для решения задачи классификации.

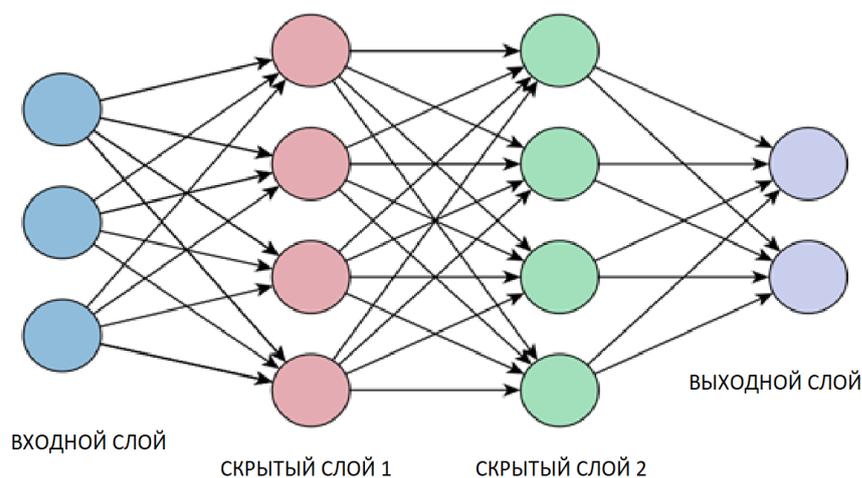


Рис. 3. Нейронная сеть с двумя скрытыми слоями.

Обучение нейронных сетей происходит при помощи корректирующих циклов обратной связи. При прохождении данных от входного к конечному выходному узлу по различным путям выбирается один правильный путь. Цикл обратной связи работает следующим образом: каждый узел первоначально делает предположение о следующем узле на пути и проверяет, является ли данное предположение правильным. Если этот путь привёл к более правильному предположению, значение веса связи повышается, и наоборот. Далее используются пути с более высоким весом, и снова повторяется первый шаг [19].

Функции активации

Функции активации – это функции, используемые в нейронных сетях для вычисления выходного сигнала на основе входных сигналов. Выходной сигнал этих функций решает, считаются ли данные, переданные нейрону, релевантными, в какой степени они должны быть переданы следующему нейрону. Чтобы иметь возможность изучать сложные задачи, нейронные сети должны добавлять к своим нейронам нелинейные функции активации. Если бы нейронные сети использовали исключительно линейные функции активации, то они могли бы решать только линейно решаемые задачи, независимо от того, сколько скрытых слоев они используют. Это связано с

тем, что композиции линейных операций скалярного произведения по-прежнему будут линейны.

Веса входных сигналов w_i обновляются, чтобы сеть могла правильно предсказать истинное значение S для каждого (или большинства) обучающего примера X . Нейронные сети с более чем одним слоем обучаемых весов могут представлять нелинейные отношения между входными и выходными переменными благодаря нелинейным функциям активации.

Существуют различные типы функций активации. Рассмотрим *ступенчатую функцию активации*. В начале выбирается граница активации. Если полученное значение функции Y больше некоторого порогового значения, то данный нейрон считается активированным. В противном случае, нейрон неактивен. Иными словами, функция будет активирована, если $Y >$ граница, иначе нет (Рис. 4).

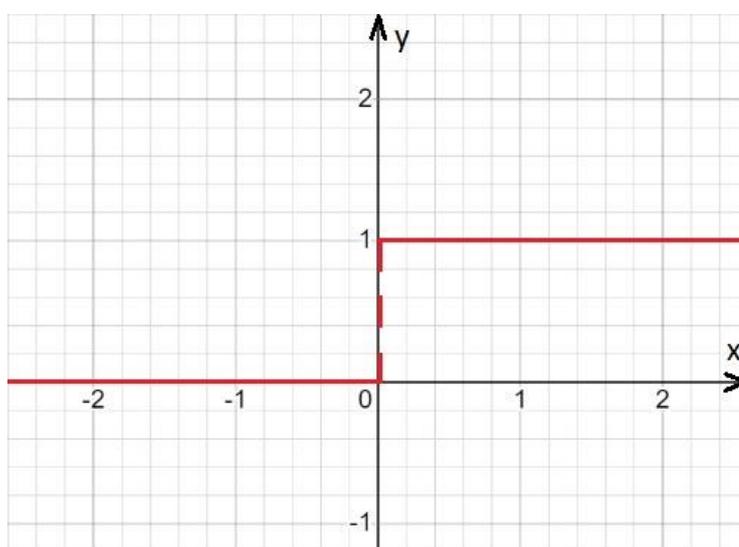


Рис. 4. Пример ступенчатой функции активации.

Ступенчатая функция принимает значение 1 (активирована), когда $Y >$ 0 (граница), и 0 (не активирована) в противном случае, но у этой функции много недостатков. Вместо того, чтобы просто принимать значения “активирована” или “не активирована” (бинарная функция), зачастую

необходимо определить промежуточное значение функции активации (аналоговая функция). В этом случае можно использовать линейную функцию активации. Уравнение и график линейной функции активации показаны ниже:

$$y = c * x . \quad (1.3)$$

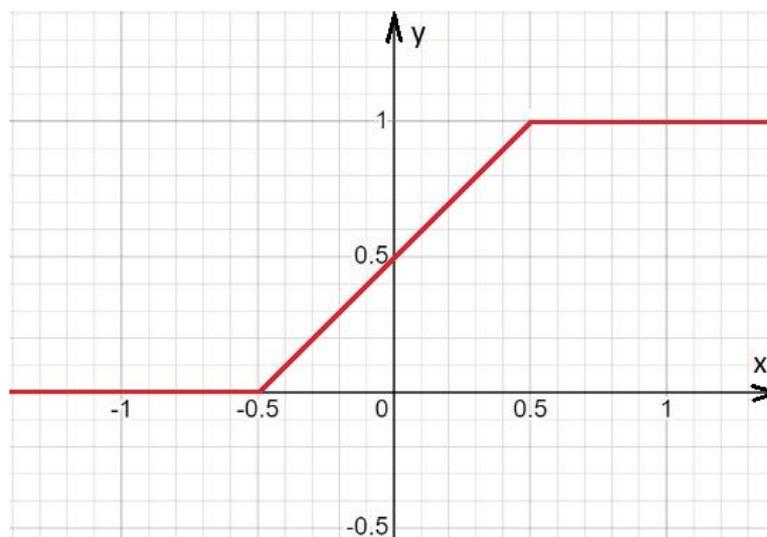


Рис. 5. Пример линейной функции активации.

Линейная функция (см. Рис. 5) представляет собой линию, пропорциональную входу, и выдаёт спектр значений вместо простого бинарного ответа. Несколько нейронов могут быть соединены вместе, и решение принимается при активации нескольких нейронов, то есть, когда функция активации сети выбрана такой же, как и функция активации нейронов в сети. Это создает проблему связанных слоев сети. Так как каждый слой активируется линейной функцией, то значение этой функции передается на вход следующего слоя, который считает взвешенную сумму своих входов, а второй слой, в свою очередь, активирует нейроны другой линейной функцией активации. Все слои линейны, и функция активации

последнего слоя будет линейной функцией входов первого слоя. Это означает, что любое количество слоев может быть заменено одним слоем, и возможность создания набора слоев теряется. Вся нейронная сеть выглядит как один слой с линейной функцией активации.

Для решения этой проблемы применяют *сигмоидальную функцию активации*, (см. Рис. 6).

$$y = \frac{1}{1+e^{-x}} . \quad (1.4)$$

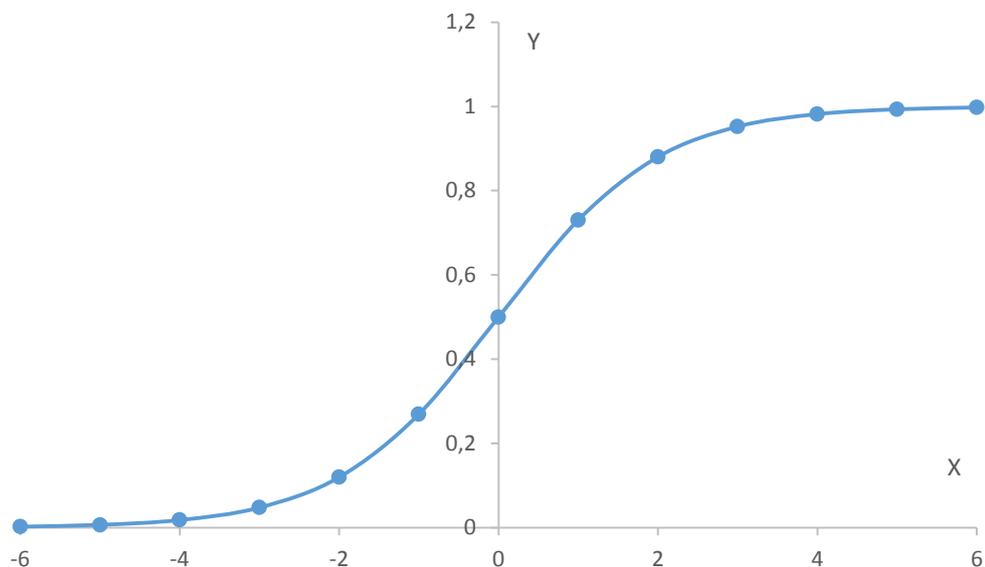


Рис. 6. Сигмоидальная функция активации.

График сигмоиды гладкий и напоминает ступенчатую функцию. Главные преимущества сигмоиды – её нелинейность и небинарность. Градиент сигмоиды плавный, в диапазоне значений x от -2 до 2 значения функции уменьшаются очень быстро, при незначительном изменении значения x в этой области значение y существенно меняется. Сигмоида является подходящей функцией для задач классификации, она стремится

привести значения к одной стороне кривой (например, вершина при $x = 2$ и дно при $x = -2$), что позволяет находить четкие границы при составлении прогнозов. Еще одно преимущество сигмоидальных функций перед линейными заключается в том, что диапазон значений функции фиксирован как $[0;1]$, в то время как линейная функция изменяется в пределах $(-\infty;+\infty)$. Это свойство сигмоиды очень полезно, поскольку она не вносит ошибок при больших значениях активации.

Подобна сигмоиде другая часто используемая функция активации – *гиперболический тангенс* (Рис. 7). Формула функции имеет следующий вид:

$$y(x) = \tanh(x) = \frac{2}{1+e^{-2x}} - 1 . \quad (1.5)$$

Фактически, гиперболический тангенс – это скорректированная сигмоидная функция:

$$\tanh(x) = 2 * \text{sigmoid}(2x) - 1 . \quad (1.6)$$

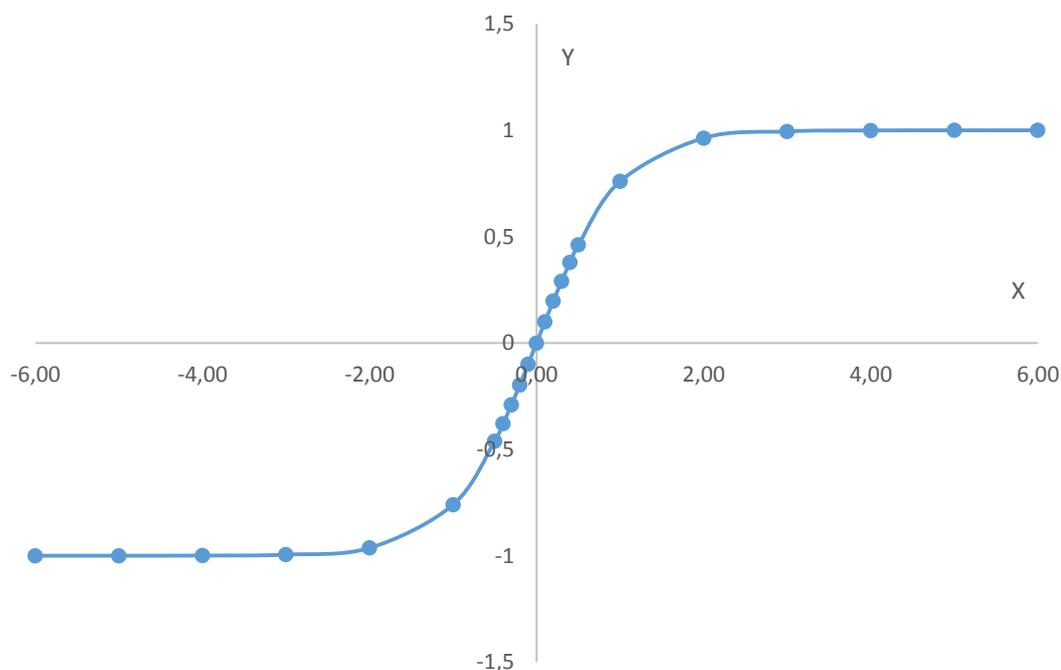


Рис. 7. Активационная функция гиперболический тангенс.

Такие функции имеют те же характеристики, что и сигмоидальные. Они не линейны и подходят для следующей комбинации слоев $\tanh(x) \in [-1;1]$. Градиент функции тангенса больше, чем у сигмоида (производная больше), поэтому выбор между ними зависит от требования к амплитуде градиента. Как и сигмоида, гиперболический тангенс имеет проблему исчезающих градиентов.

Rectified Linear Unit (ReLU) – это наиболее часто используемая функция активации при глубоком обучении. Она может быть записана следующим образом:

$$y = \max(0, x) . \tag{1.7}$$

ReLU возвращает значение x , если x положительно, и 0 в противном случае. Её график представлен на Рис. 8.

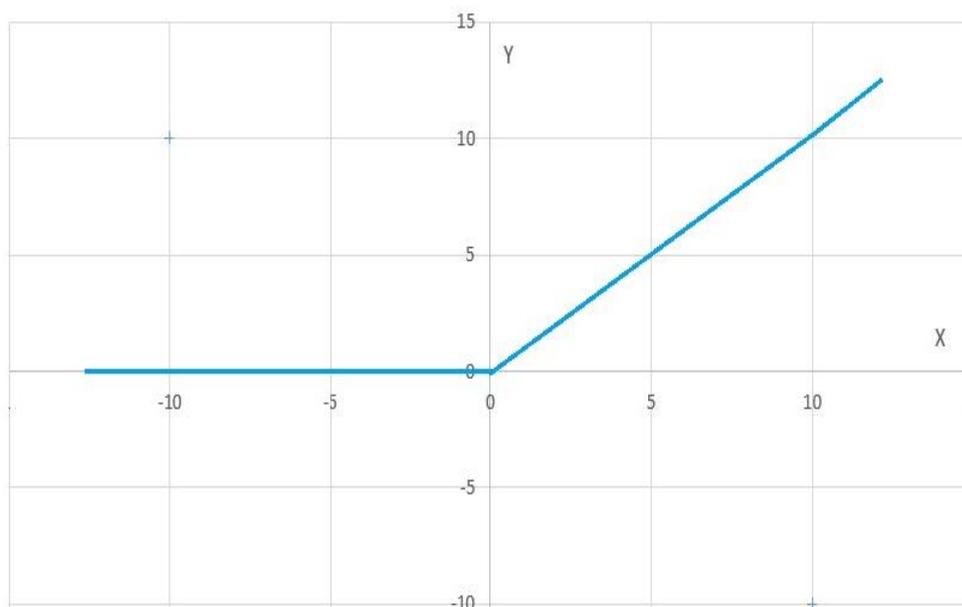


Рис. 8. Активационная функция ReLU, x – входной сигнал.

Функция ReLU имеет ряд преимуществ перед сигмоидой (1.4) и гиперболическим тангенсом (1.6):

1. Лёгкое вычисление производной (для отрицательных значений она равна нулю, а для положительных – единице).
2. Разреженность активации. ReLU задействует малое количество активируемых нейронов в сравнении с сигмоидой и гиперболическим тангенсом, что делает сеть более простой и быстрой в обучении.

Недостатком функции является так называемая "проблема умирания ReLU". Поскольку производная части функции равна нулю, ее градиент равен нулю, веса не меняются в процессе спуска, и нейронная сеть перестает обучаться. В целом, благодаря своей математической простоте, функция ReLU сегодня чаще всего используется при создании глубоких нейронных сетей.

Свёрточные нейронные сети

Существуют различные типы нейронных сетей, и каждый из них имеет свои преимущества и недостатки. В этом параграфе мы рассмотрим класс свёрточных нейронных сетей (*англ.* convolutional neural network, CNN), которые хорошо подходят для задач компьютерного зрения. Вместо того, чтобы получать входные данные в виде вектора значений пикселей (как в нейросетях прямого распространения), CNN получают их в виде матрицы значений пикселей (с шириной, высотой и глубиной изображения). Таким образом, мы можем сохранить пространственные отношения внутри изображений. CNN подобны искусственным нейронным сетям, описанным выше, но каждый нейрон связан только с набором нейронов в предыдущих слоях (локальная связность), а веса распределяются в соответствии с принципами, используемыми зрительной корой человека. Впервые они были представлены К.Фукусимой в 1980 году [38] и использовались вместе с обратным распространением Я.Лекуном в 1989 году [12] в работе, которая с тех пор вдохновляет разработчиков на их использование в компьютерном зрении. В последние годы несколько архитектур CNN, таких как AlexNet, ResNet и DenseNet, продемонстрировали современную производительность в самых различных задачах компьютерного зрения. В 2012 г. была разработана восьмислойная сеть AlexNet. Сеть AlexNet - первая глубокая свёрточная нейронная сеть, которая стала прообразом многих современных архитектур CNN. Свёрточные нейронные сети были предложены ещё в 1990-х годах, но на тот момент были отодвинуты на второй план в пользу более теоретически строгих подходов машинного обучения, таких как машины опорных векторов. С течением времени они превзошли другие модели по двум основным причинам. Во-первых, накопился большой объем высококачественных данных для обучения. База данных ImageNet, на основе которой производилось распознавание изображений, была единственным в своем роде эталоном и состояла из более чем 14 миллионов аннотированных вручную изображений из более чем 20 тысяч различных категорий. Многоуровневая свёрточная сеть обладала способностью эффективно

запоминать обучающее подмножество ImageNet. Во-вторых, графические процессоры (GPU), которые изначально были разработаны для распараллеливания задач обработки изображений, оказались идеально подходящими для решения вычислительных задач, связанных с обучением свёрточных сетей, что сделало возможным обучение на больших наборах данных за малое время. Сочетание больших данных, больших моделей и относительно дешёвых параллельных вычислений стало тем фундаментом, на котором сейчас базируются исследования в сфере искусственного интеллекта во всех дисциплинах, а также во всех приложениях, которые имеют элементы данных и прогнозирования.

Рассмотрим элементы свёрточной нейронной сети:

1. слой свёртки;
2. пулинг;
3. нормализация;
4. получение полносвязного слоя.

На каждом слое выполняется несколько типовых операций над изображением, самая важная из которых – свёртка. В процессе свертки нейронная сеть отсеивает ненужные данные и оставляет полезные. Свёртка может быть создана для каждого признака, сеть сама подбирает признаки в процессе распознавания и классификации на каждом слое свертки.

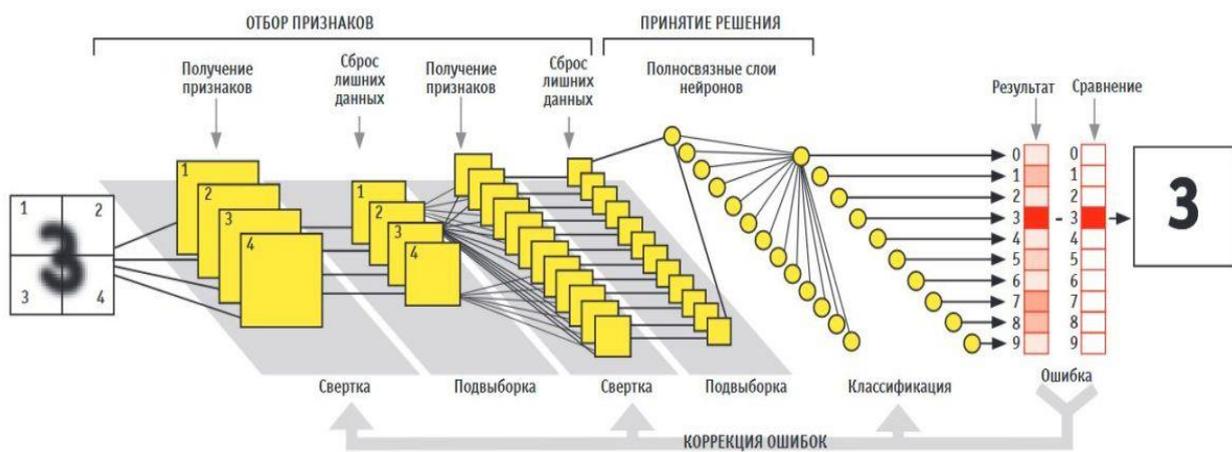


Рис. 9. Структура свёрточной нейросети. Свёртка и пулинг (предвыборка) чередуются несколько раз, чтобы выделять всё более сложные признаки.

Слой свёртки чередуется слоем предварительного отбора (объединения) (Рис. 9). Выстраивается иерархия признаков, от примитивных до сложных.

Первые слои нейросети анализируют мелкие детали изображения (см. Рис. 10). На таких маленьких изображениях трудно различить детали, но можно найти различия в цвете и свете, то есть границы между различными объектами. Далее, последующие слои работают со всё более сложными объектами.

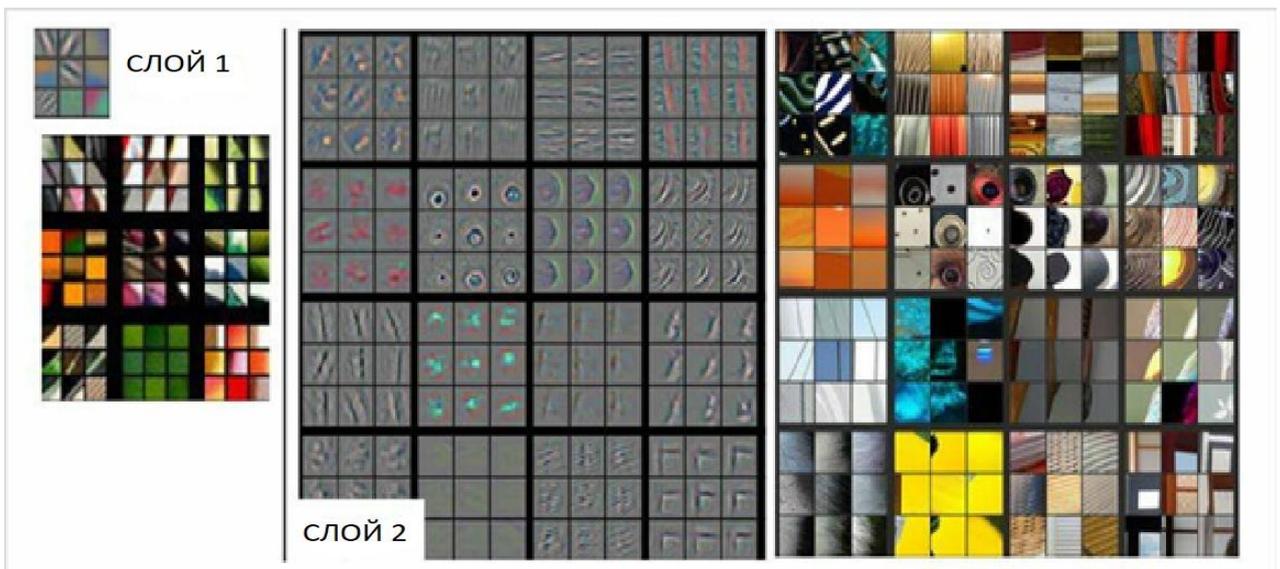


Рис. 10. Первые слои нейросети. Поиск границ объектов по перепадам света.

Качество обработки и результатов обучения сети, как правило, зависят от числа слоёв сети. Чем их больше, тем более высокие результаты может показать сеть. Извлекаются всё более сложные признаки, которые связываются с конкретными изображениями (см. Рис. 11).

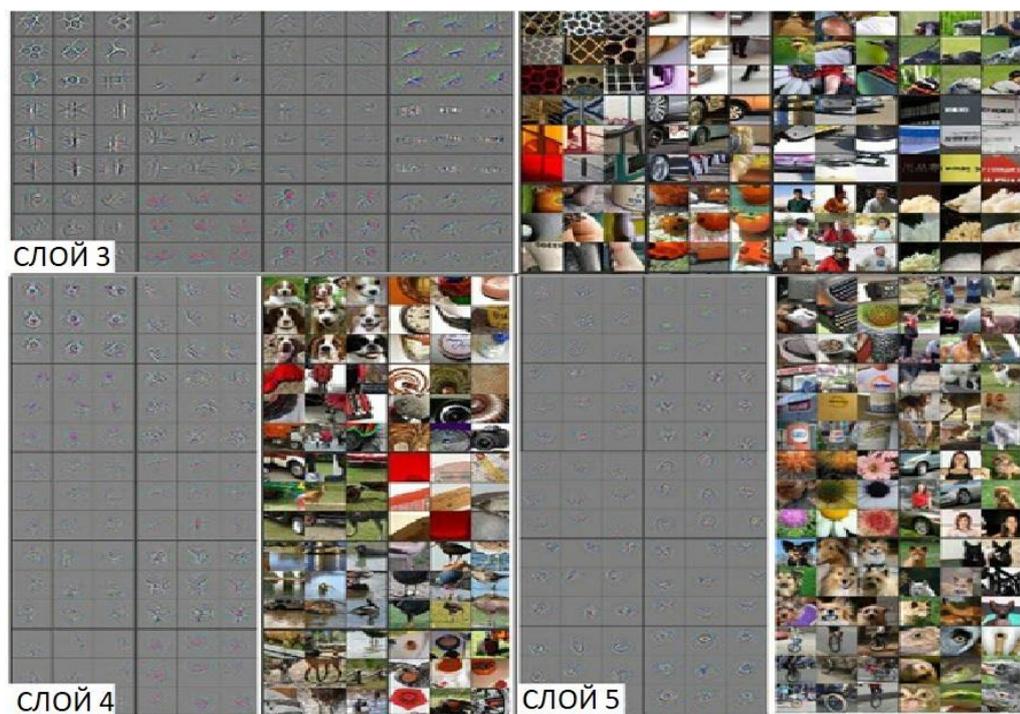


Рис. 11. Последующие слои нейросети. Нейросеть пытается понять, что перед ней.

Нейронные сети обучаются на цветных изображениях RGB. Пиксели передают яркость по трем каналам: красному, зеленому и синему, различные комбинации этих цветов дают любой цвет из спектра.

Свёрточные нейронные сети рассматривают изображение как трехмерный массив чисел или матрицу. В математике такой массив называется тензором (Рис. 12). Цвет пикселя закодирован в нём в виде трёх целых чисел от 0 до 255. Соответственно, каждый пиксель в массиве матриц представлен в виде числа, которое показывает его яркость в этом диапазоне.

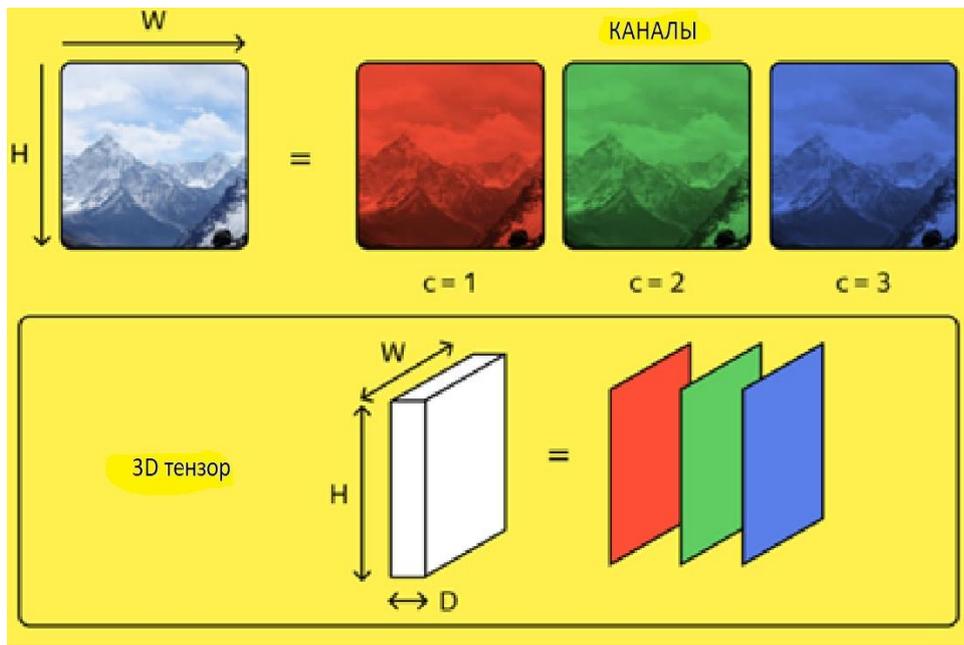


Рис. 12. Тензор изображения в формате RGB. Изображение состоит 3 массивов, каждый массив отвечает за определённый цвет: красный, синий, зелёный.

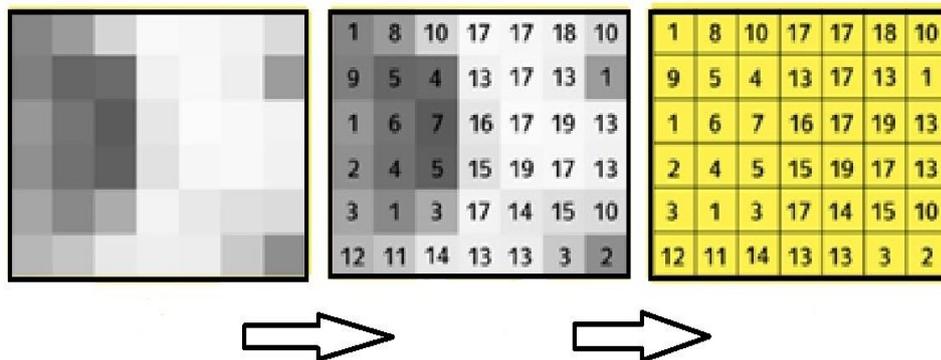


Рис. 13. Слева - изображение, разбитое на пиксели, по центру - каждый пиксель получил значение от 0 до 255, справа - массив, с которым работает свёрточная нейронная сеть.

Изображения, полученные различными способами, часто искажены помехами, и человеку сложно анализировать их визуально или обрабатывать автоматически с помощью программного обеспечения.

Рассмотрим свёртку на примере одного пикселя. Через каждый пиксель проходит фильтр (ядро свертки). На рисунке выбран пиксель со значением 2. Сначала нужно перемножить значения матрицы свертки на выбранный пиксель и соседние с ним пиксели по очереди, а затем сложить их все вместе.

Затем значение первого пикселя исходного изображения заменяется полученным значением 13, а значения соседних пикселей остаются неизменными. Такую же операцию выполняют для каждого пикселя изображения (см. Рис. 14).

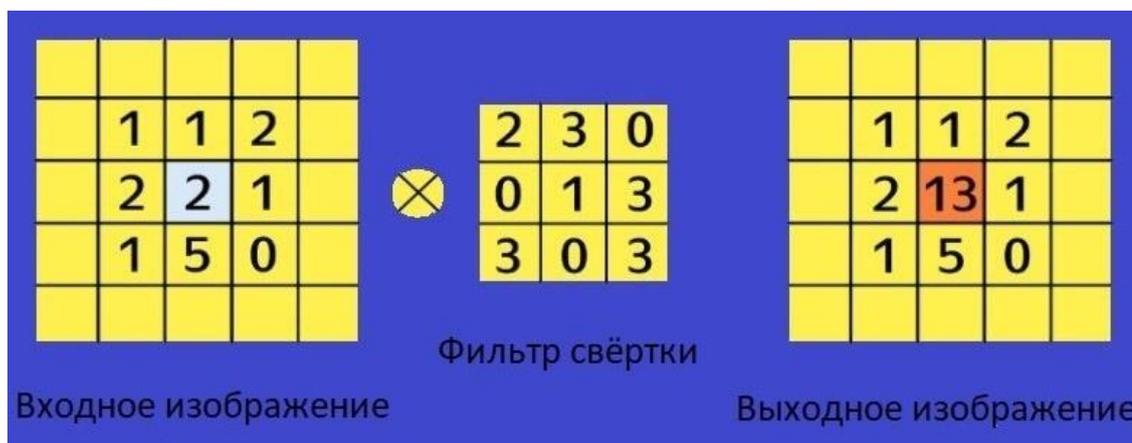


Рис. 14. Свёртка на примере одного пикселя.

Сама техника свертки для всего изображения выглядит следующим образом:

1. Фильтр проходит через каждый пиксель изображения, умножает свою матрицу на значения матрицы изображения и складывает их вместе. На выходе получается новая матрица.
2. Значения полученных матриц суммируются, образуя единую матрицу.
3. К каждому номеру матрицы добавляется одно и то же число - значение, на которое переместился фильтр, то есть шаг свертки. Шаг равен 1 – фильтр переместился на один пиксель. Шаг равен 2 – фильтр сдвинулся на два пикселя. Итоговая матрица - это один канал выходной карты признаков.
4. Все каналы (матрицы), полученные после фильтрации изображения, объединяются в один тензор. В результате получается изображение разного размера и с разным количеством каналов.

Архитектуру конволюционных нейронных сетей лучше всего понять на примере двух нейронных сетей - ResNet и U-Net. Эти сети похожи, но используются для разных задач: ResNet -для классификации, а U-Net – для сегментации.

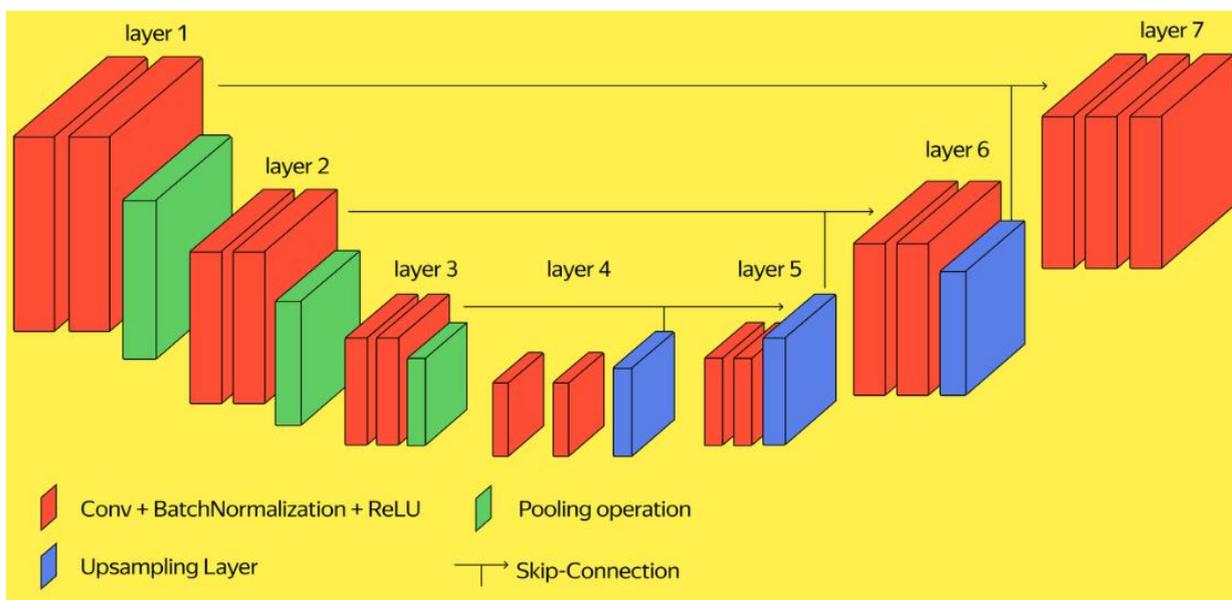


Рис. 15. Архитектура сети U-Net состоит из нескольких слоёв, часть из которых чередуются.

Например, камере видеонаблюдения нужно определить, где на дороге пешеход. В U-Net изображение проходит два пути (см. Рис. 15). Сначала нейронная сеть пропускает изображение через слои свертки и объединения. Таким образом, она определяет, кто или что находится на изображении. Красный слой содержит свёртку, нормализацию для стабильности обучения и функцию активации ReLU. Это помогает отбросить несущественные признаки и выбрать только необходимую информацию. Зеленый слой – это объединяющий слой. Здесь происходит сжатие изображения. Например, изображение размером 224x224 превращается в 112x112. Таким образом, нейронная сеть тратит меньше вычислительной мощности на обработку изображений меньшего размера. Это также важно, когда необходимо определить доминирующие признаки в изображении.

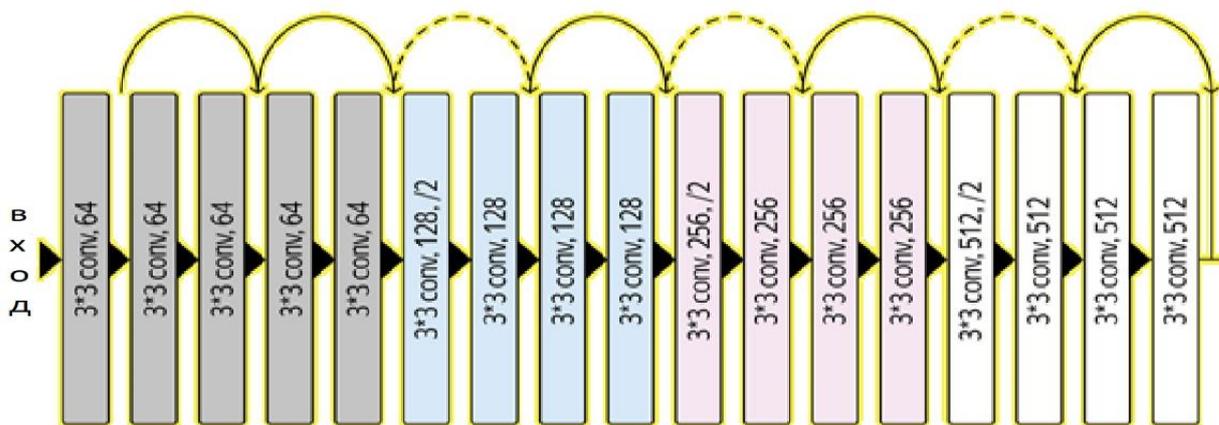


Рис. 16. Архитектура ResNet. Каждые несколько строк происходит пулинг и сжимает изображение.

Сверточная нейронная сеть ResNet тоже состоит из нескольких типовых шагов с типовыми операциями: свёртка, нормализация и пулинг (см. Рис. 16).

В моей работе использована нейросеть Inception v3 от разработчиков компании Google LLC. Inception v3 – это свёрточная нейронная сеть, созданная для помощи в анализе изображений и обнаружении объектов, которая возникла как модуль для нейронной сети GoogLeNet. Это третье издание сверточной нейронной сети Google Inception, первоначально представленное во время конкурса ImageNet Recognition Challenge. Дизайн сети Inception v3 предназначен для обеспечения более глубоких сетей, а также для предотвращения слишком большого роста количества параметров: он имеет менее 25 миллионов параметров по сравнению с 60 миллионами для AlexNet [62]. Inception v3 уже успешно использовалась для диагностики ретинопатии и меланомы. Исследователи обучили нейросеть на 3000 изображений с результатами гистологии патологических тканей, используя графические процессоры NVIDIA Tesla с расширенной cuDNN и платформу TensorFlow. Исследование показало, что свёрточные нейронные сети, такие как Google Inception v3, могут быть использованы для анализа результатов гистологии и диагностики рака легких: алгоритм классифицирует здоровые и опухолевые ткани с точностью $\sim 0,99$ AUC, и различает типы рака лёгких с

высокой точностью - 0,97 AUC, достигая точности, сравнимой с результатами врача патологоанатома [31].

1.2. Логистическая регрессия

Логическая регрессия - это метод анализа данных, который использует математику для нахождения взаимосвязи между двумя факторами данных. Затем полученная взаимосвязь используется для прогнозирования значения факторов на основе других факторов.

Логистическая регрессия – это статистическая модель, которая использует логистические или логит-функции в математике в виде уравнений между x и y . Логит-функция отображает $f(x)$ как сигмовидную функцию от x .

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1.8)$$

Функция логистической регрессии приведена ниже на Рисунок 17.

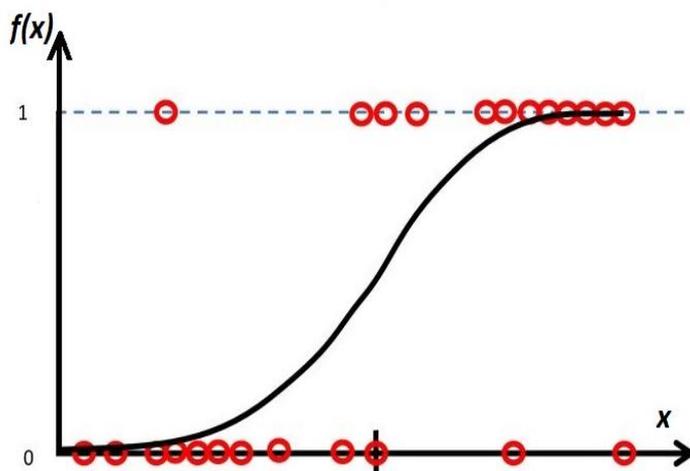


Рисунок 17. Функции логистической регрессии.

Логитная функция возвращает только значения от 0 до 1 для зависимой переменной, независимо от значения независимой переменной. Именно так

логистическая регрессия оценивает значения зависимых переменных. Метод логистической регрессии также моделирует уравнения между несколькими независимыми переменными и одной зависимой переменной.

Логистическая регрессии имеет ряд преимуществ перед другими методами машинного обучения: математическая простота, скорость обработки данных, гибкость и наглядность.

Бинарная логистическая регрессия используется, когда зависимая переменная является двоичной (то есть может принимать только 2 значения).

$$y = a + b_1 * x_1 + b_2 * x_2 + \dots + b_n * x_n . \quad (1.9)$$

1.3. Метод К-ближайших соседей

К-ближайшие соседи (*англ.* k-nearest neighbours, KNN) - это алгоритм контролируемой классификации (с учителем). Он находит применение в задачах, связанных как с классификацией, так и с регрессией.

Цель метода – сгруппировать похожие последовательности. Данное изначально множество разбивается на заранее известное k кластеров. При каждой итерации алгоритм минимизирует среднеквадратичное отклонение точек каждого кластера:

$$E(\mu_i) = \sum_{i=1}^k \sum_{x \in \mu_i} (x - \mu_i)^2 . \quad (1.10)$$

$$\text{Далее, } \frac{\partial E(\mu_i)}{\partial (\mu_i)} = 0 \quad \text{и} \quad (1.11)$$

$$\min E(\mu_i) = \min \sum_{i=1}^k \sum_{x \in \mu_i} (\|x_i - \mu_i\|)^2 , \quad (1.12)$$

где C – получаемые кластеры, μ_0 – центры масс векторов X .

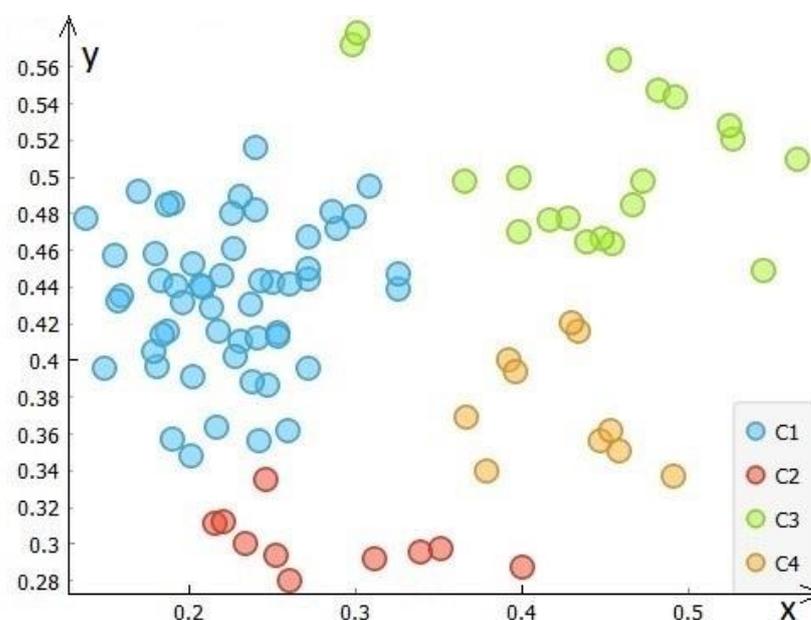


Рис. 18. Иллюстрация работы метода KNN в программе Orange Data Mining.

Метод k -средних – это итеративный алгоритм, который пытается разбить набор данных на k predetermined отдельных непересекающихся подгрупп (кластеров), где каждая точка данных принадлежит только одной группе. Производительность KNN во многом зависит от выбора подходящего значения для k и нормализации данных. Он особенно эффективен для наборов данных с четко определенными кластерами или областями схожих экземпляров и широко применяется в различных областях, включая распознавание изображений, системы рекомендаций и медицинскую диагностику. KNN классифицирует элементы, оценивая сходство признаков, которые представляют собой входные переменные. Несмотря на то, что KNN относится к области контролируемого машинного обучения, он не требует отдельного этапа обучения и использует все доступные данные на этапе классификации.

Метод KNN - это простой алгоритм машинного обучения с учителем, который можно использовать для решения задач классификации и регрессии.

Его легко реализовать, но у него есть существенный недостаток – он значительно замедляется при увеличении объема данных.

1.4. Машина опорных векторов

Машина опорных векторов (*англ.* support vector machine, SVM) – это алгоритм контролируемого обучения, применяемый для задач классификации и регрессии. Цель SVM – обнаружить оптимальную гиперплоскость, которая эффективно различает точки данных, принадлежащие к разным классам, максимально увеличивая пространство между ними. Этот метод включает преобразование данных в область более высокого измерения для повышения различимости с последующим выбором гиперплоскости, которая максимизирует разрыв между ближайшими точками данных каждой категории. SVM оказывается выгодным при управлении многомерными данными и решает задачи линейной и нелинейной классификации за счет включения функций ядра. Он известен своей способностью управлять сложными границами принятия решений и высокой производительностью обобщения. Машина опорных векторов (SVM) иллюстрирует данные обучения, представляя точки в пространстве, четко классифицированные с максимально широким интервалом. Сохранение этого разрыва предполагает введение линии, параллельной гиперплоскости, устанавливающей границу между категориями для прогнозирования размещения новых экземпляров данных.

Машина опорных векторов разделяет классы линией или границей (называемой гиперплоскостью). Они используют гиперплоскости, чтобы максимально отделить точки данных одного класса от другого, то есть максимизировать расстояние между гиперплоскостью и ближайшими точками данных каждого класса (Рис. 19).

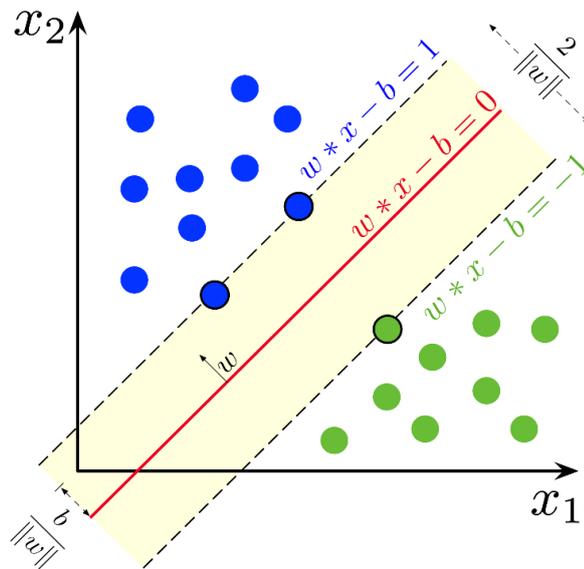


Рис. 19. Машина опорных векторов.

Если мы пытаемся классифицировать изображение как “кошка” или “собака”, машина опорных векторов найдет линию, разделяющую эти два изображения. Входными данными для SVM являются характеристики каждого изображения (например, цвет, текстура, форма изображения). Далее, алгоритм находит лучшую гиперплоскость, которая разделяет два класса изображений с максимально возможным запасом (расстоянием между гиперплоскостью и ближайшими точками данных).

Каждый объект данных представлен в виде вектора в P -мерном пространстве (последовательности чисел). Предположим, у нас есть набор объектов и тестовая коллекция с набором классов. Математическая задача обучения состоит в том, чтобы найти функции, которые должным образом соотносят объекты и классы, то есть функции, которые эффективно разделяют объекты в пространстве.

Нахождение уравнения на плоскости является стандартной задачей квадратичного программирования и решается с использованием множителей Лагранжа. В этом и состоит процесс обучения. Как только плоскость найдена, выбирается новый объект и его положение относительно плоскости.

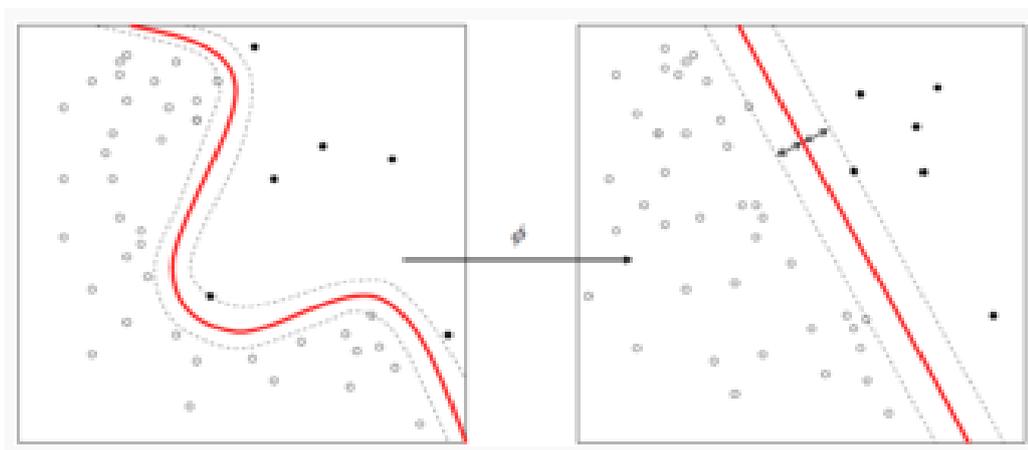


Рис. 20. Нахождение разделяющей прямой.

На практике часто бывает так, что объект расположен таким образом, что невозможно провести разделительную линию на плоскости. В этом случае плоскость встроена в пространство большего размера. При встраивании плоскость преобразуется таким образом, что можно провести разделяющую плоскость (см. Рис. 20).

1.5. Наивный Байес

Теорема Байеса названа в честь ее автора английского математика Томаса Байеса (XVIII в.). Томас Байес был первым математиком, использующим условную вероятность для создания алгоритма. Этот алгоритм классификации работает на принципах теоремы Байеса и включает в себя вероятности, предназначенные для прогнозирования вероятности принадлежности экземпляра к определенному классу. Предполагается, что с учетом метки класса функции условно самостоятельны, отсюда и обозначение “наивные”. Наивный Байес особенно эффективен для категоризации текста и демонстрирует умение работать с данными значительных размеров. Он эффективен в вычислительном отношении, прост в реализации и может обрабатывать непрерывные и категориальные

функции. Несмотря на предположение о независимости, наивный Байес часто дает конкурентоспособные результаты в различных реальных приложениях. Алгоритм наивной байесовской классификации используется как для двухклассовых, так и для многоклассовых классификационных заданий. Этот подход прост и понятен, особенно при обработке двоичных или категориальных входных данных. В этом классификаторе каждый признак оценивается изолированно, вне зависимости от других признаков. Например, фрукт можно идентифицировать по его цвету, вкусу и форме, например, классифицируя апельсин как круглый, сладкий и терпкий. Часто используемый для обширных наборов данных, он выделяется как один из самых простых и быстрых подходов к машинному обучению, часто дающий благоприятные результаты.

Наивный Байесовский алгоритм (Naive Bayes) относится к вероятностным алгоритмам, основанным на применении теоремы Байеса, позволяющей определить вероятность события при условии, что произошло другое взаимозависимое с ним событие. Алгоритм использует вероятность для вычисления пределов неизвестного параметра:

$$P(y|x) = \frac{P(x|y)P(y)}{P(x)}. \quad (1.13)$$

$P(x)$ – априорная вероятность наступления события А (гипотеза)

$P(e)$ – априорная вероятность наступления события В

$P(x/y)$ – вероятность наступления события А, при наступлении события В.

$P(y/x)$ – частота возникновения события В, при наступлении события А.

В результате формула Байеса дает возможность переоценить априорные представления о мире ($P(y)$) на основе частичной информации (данных), полученных в виде наблюдений ($P(x/y)$), в качестве вывода получая новое состояние этих представлений ($P(y/x)$), то есть наивный Байесовский алгоритм исходит из предположений, что все атрибуты независимы, одинаково важны и в равной степени влияют на результат.

Наивный Байесовский алгоритм имеет множество применений: фильтрация спама, классификация документов, и др. Наивному Байесу требуется лишь небольшое количество обучающих данных для оценки требуемых параметров. С другой стороны, наивный байесовский алгоритм известен своей невысокой оценкой, поскольку предполагает, что все признаки имеют одинаковую важность, что неверно в большинстве реальных сценариев.

1.6. Дерево решений

Дерево решений – это метод предоставления решающих правил в иерархической структуре, состоящей из двух типов узлов и листьев. Дерево решений (*англ.* Decision Tree) – это графическое представление процесса принятия решений, которое моделирует результаты путем рекурсивного разделения данных на подмножества в зависимости от входных характеристик. Каждый внутренний узел символизирует решение или исследование, связанное с определенной характеристикой, ведущее к ветвям, соответствующим возможным результатам. Конечные узлы, также известные как листья, представляют собой окончательные классификации или прогнозы. Он облегчает задачи классификации и регрессии за счет рекурсивного разделения входных данных на подмножества на основе наиболее влиятельных признаков. Каждое деление создает древовидную структуру, где внутренние узлы соответствуют тестам атрибутов, а листья представляют прогнозируемые результаты. Деревья решений интерпретируются, что обеспечивает прозрачные процессы принятия решений (Рис. 21). Они способны обрабатывать как категориальные, так и числовые данные и фиксируют сложные взаимосвязи. Однако они могут быть склонны к излишней классификации.

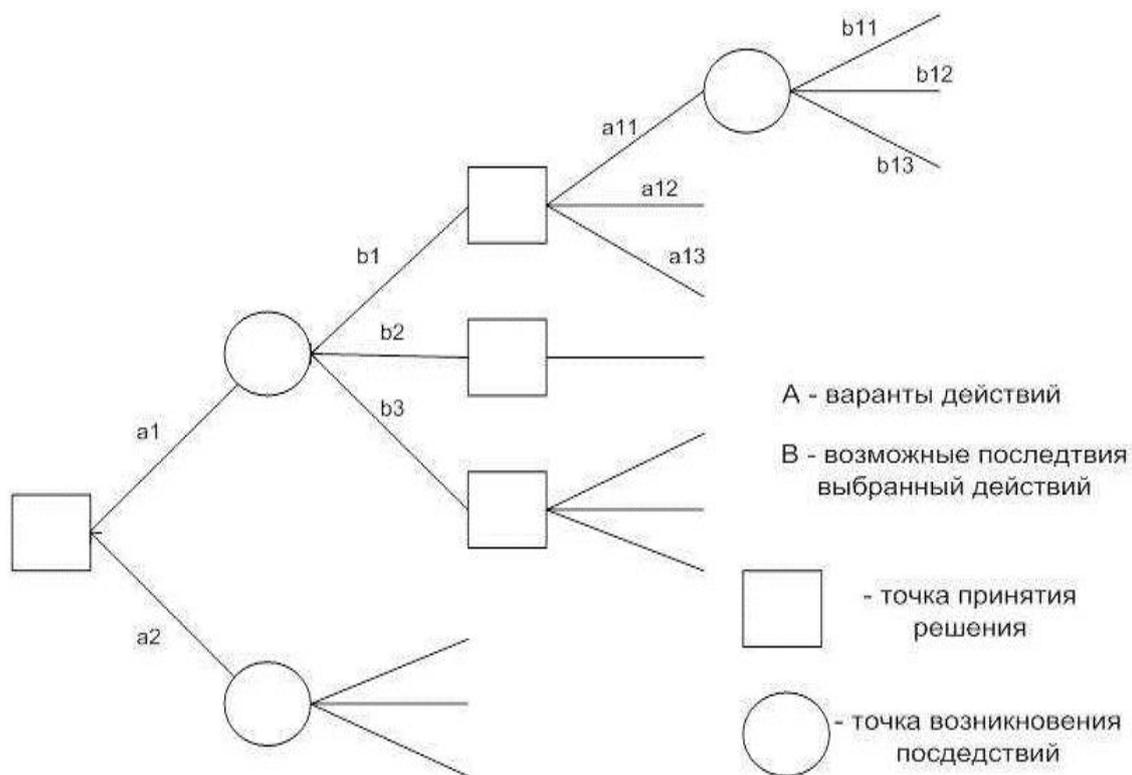


Рис. 21. Принцип работы метода классификации дерево решений.

Дерево решений – это простейший и самый надежный метод классификации в интеллектуальном анализе данных. Это блок-схема, похожая на древовидную структуру, которая состоит из “узлов” и “веток”. Основной корневой узел представляет собой всю выборку, которая в последующем делится на два и более однородных подузла. Узел, разделенный на подузлы, называется родительским узлом, тогда как подузлы являются дочерними элементами родительского узла. Если подузел разделяется на дополнительные подузлы, он называется узлом принятия решений. Узлы, которые не разделяются являются конечными узлами. Ветвью считается отдельная часть дерева. Разделение атрибутов данных происходит согласно правилу: “если – условие, то результат”, по принципу максимального снижения энтропии результирующего подмножества относительно родительского. Дерево разбивает данные и сопоставляет их записям, не входящим в обучающий набор.

1.7. Случайный лес

Случайный лес представляет собой метод ансамблевого обучения в области машинного обучения. Он состоит из нескольких деревьев решений и объединяет их прогнозы для повышения точности и уменьшения переобучения. Метод поддерживает различные типы данных, обрабатывает многомерные пространства и предлагает внутреннее ранжирование важности функций. Его приложения охватывают самые различные области знаний, подтверждая его статус идеального алгоритма для сложных задач классификации и регрессии, известного своей стабильностью, масштабируемостью и устойчивостью к зашумленным данным.

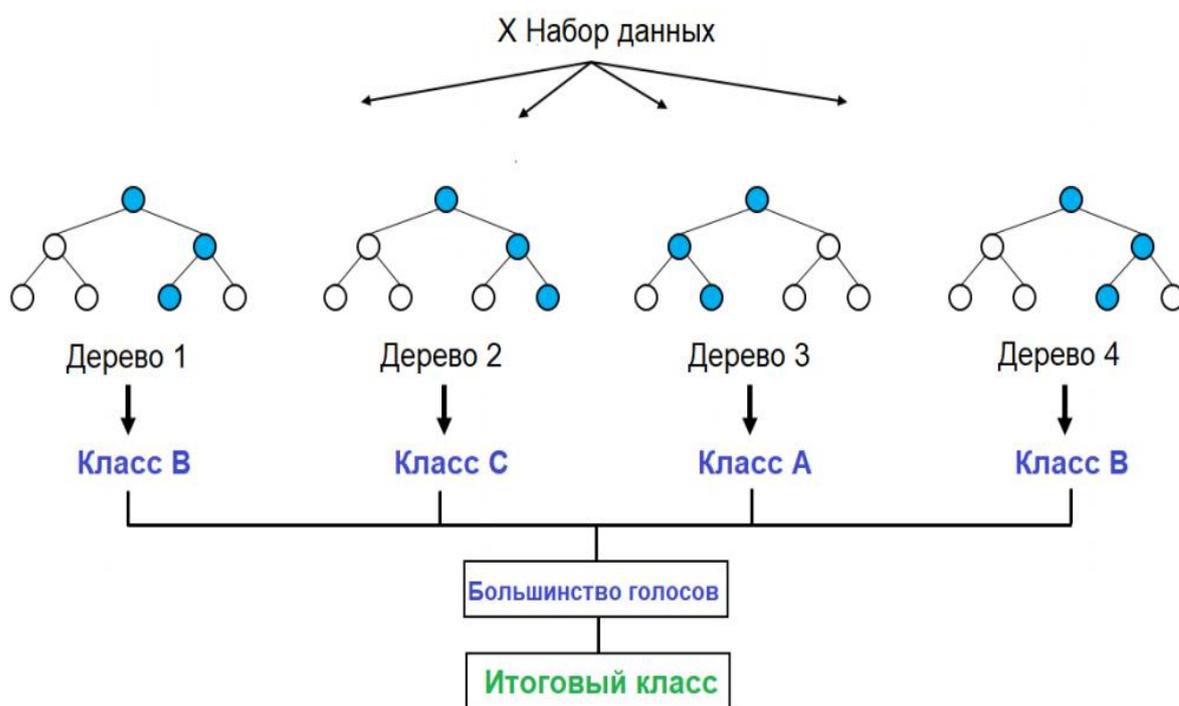


Рис. 22. Принцип работы метода классификации случайный лес.

1.8. Программная среда исследования Orange Data Mining

В представленной работе рассматриваются параметры и делается прогноз для МРТ-изображений головного мозга с использованием инструмента интеллектуального анализа данных Orange Data Mining. Программа была разработана лабораторией биоинформатики Люблянского университета и институтом Йозефа Стефана (Bioinformatics Laboratory, Faculty of Computer and Information Science, University of Ljubljana, Slovenia). Данная программа является системой визуального программирования с открытым исходным кодом, который доступен для модификации и свободного распространения, написанной на языке программирования Python. Язык Python сегодня является де-факто стандартом в разработке интернет-приложений, программного обеспечения, машинном обучении. Программа Orange Data Mining предназначена для интеллектуального анализа данных, статистических исследований и визуализации данных. Она позволяет пользователям проводить эксперименты, создавать алгоритмы для прогнозных моделей, импортировать и экспортировать данные, проводить статистический анализ, составлять отчеты и анализировать данные, создавать их визуализацию и широко использовать интеллектуальный анализ данных. Интерфейс программы интуитивно понятен и легок в освоении для исследователя и не требует глубокого погружения в программирование. Благодаря этим свойствам, программа Orange Data Mining используется в биомедицине, биоинформатике, геномных исследованиях [56]. В научных исследованиях программа используется как платформа тестирования новых алгоритмов машинного обучения, при внедрении новых методов в генетике и биоинформатике. Для специалистов в области анализа данных, исследователей и ученых, данная аналитическая система является удобным и эффективным инструментом. Компоненты программы называются виджетами. Рабочий стол программы Orange Data Mining используется для размещения виджетов и создания рабочего процесса анализа данных.

Виджеты содержат базовые функциональные возможности, например, чтение данных, отображение таблицы данных и так далее. Каждый виджет представляет собой программный модуль, который обрабатывает поступившую на его вход информацию и передает её дальше, для обработки, визуализации или сохранения последующим виджетом.

1.9. Выводы по главе 1

Несмотря на популярность нейронных сетей, их применение затруднено по нескольким причинам. Нейронные сети фактически "изобретают" и дополняют имеющееся изображение вместо того, чтобы подавлять шум, так что результаты обработки изображения, отличные от тех, которые использовались в обучающей выборке, могут быть непредсказуемыми. Использование нейронных сетей для подавления шума на изображениях требует высоких вычислительных затрат и определенных требований к оборудованию, что ограничивает их использование на некоторых типах компьютеров. Учитывая особенности цифровых медицинских изображений, такие как дискретность и наличие границ допустимых значений, использование некоторых методов сглаживания в чистом виде может не дать желаемого результата, требуется дальнейшая доработка этих методов.

Глава 2. Исследовательская часть.

Распознавание МРТ-изображений

Основная цель данной главы – исследование алгоритмов классификации в задаче обработки медицинских цифровых контрастных изображений. В процессе исследования выполняется сравнительный анализ различных алгоритмов реализации классификации новообразований в головном мозге при обработке цифровых контрастных МРТ-изображений.

2.1 Подготовка данных

Обучающая база данных – это набор изображений, при помощи которых происходит обучение диагностической модели.

Медицинское изображение представляет двумерную или трёхмерную визуальную информацию о внутренних структурах и функциях человеческого тела.

Технология обработки медицинских изображений включает в себя следующие основные этапы:

1. Получение максимально детализированного исходного изображения.
2. Предобработка полученного изображения – уменьшение шума в изображениях (см. Рис. 23). Методы шумоподавления в медицинских изображениях условно делятся на две категории: при получении и после получения изображения. Первая категория методов относится к специальным модулям обработки, добавляемым в систему получения изображения для подавления шума. Вторая категория – методы цифровой обработки изображений [49].

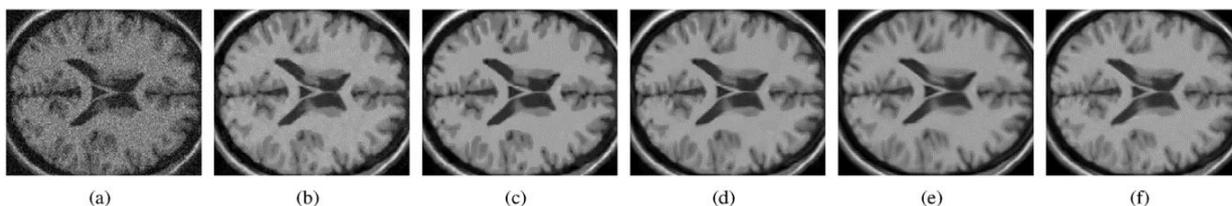


Рис. 23. (а) МРТ-изображение, содержащее шум; (b) – (f) результат работы алгоритмов уменьшения шума в изображении.

3. Изменение контрастности (выделение зон интереса).
4. Сегментация изображения, выделение части снимка, с которой в дальнейшем будет работать программа распознавания. Процесс отделения областей интереса от фона и друг от друга.
5. Распознавание, в ходе которого происходит извлечение так называемых атрибутов (признаков) изображения, установление взаимосвязей между ними.
6. Этап машинного обучения и тестирования обученной модели.
7. Классификация изображений по категориям. Сортировка информации по категориям по качествам и характеристикам.
8. Получение результатов, их интерпретация и оценка.

Алгоритм обработки медицинских изображений обобщённо можно представить в виде следующей блок-схемы: см. Рис. 24.

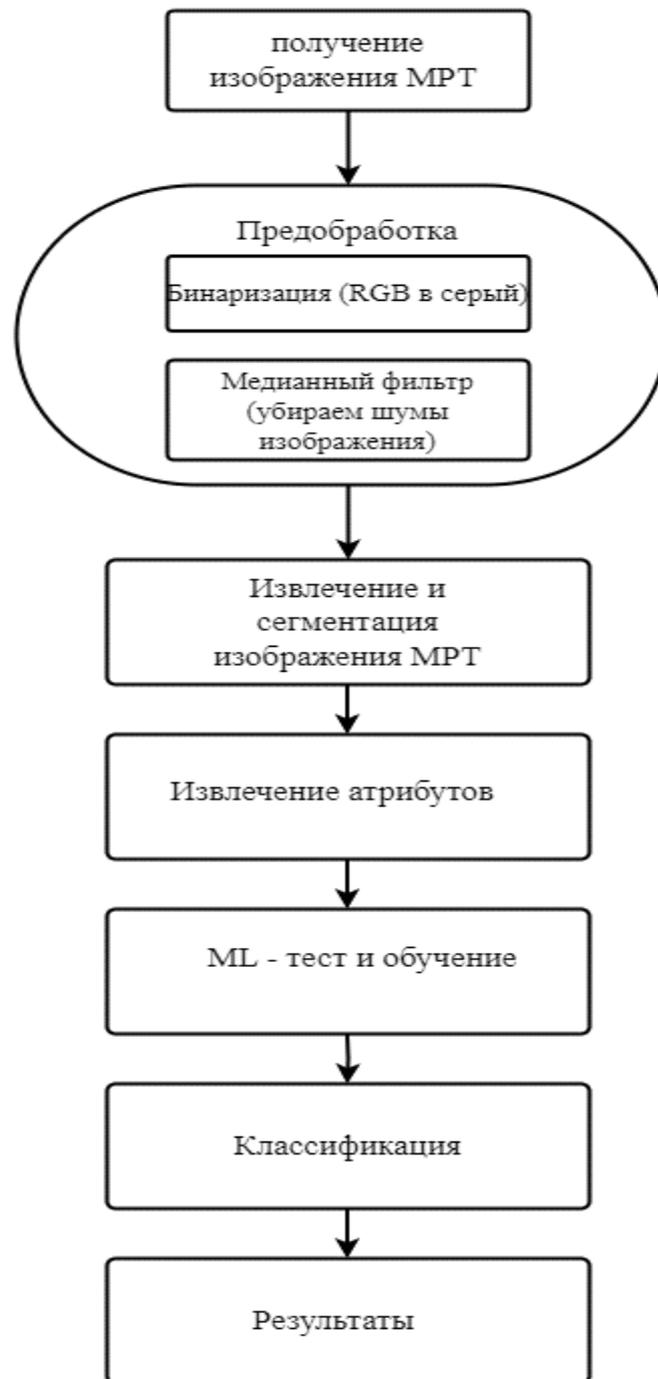


Рис. 24. Алгоритм обработки медицинских изображений.

2.2. Описание набора данных для исследования

Разработанный автором работы классификатор может обрабатывать анатомические модели из любого источника, в нашем примере мы используем изображения головного мозга, полученные на основе МРТ-сканирований *in vivo*. В исследование было включено 155 пациентов с различными типами опухолей головного мозга и 98 пациентов с нормальными МРТ-изображениями (см. Рис. 25).

Все различные гистопатологические подтипы опухолей были сгруппированы вместе для целей анализа.

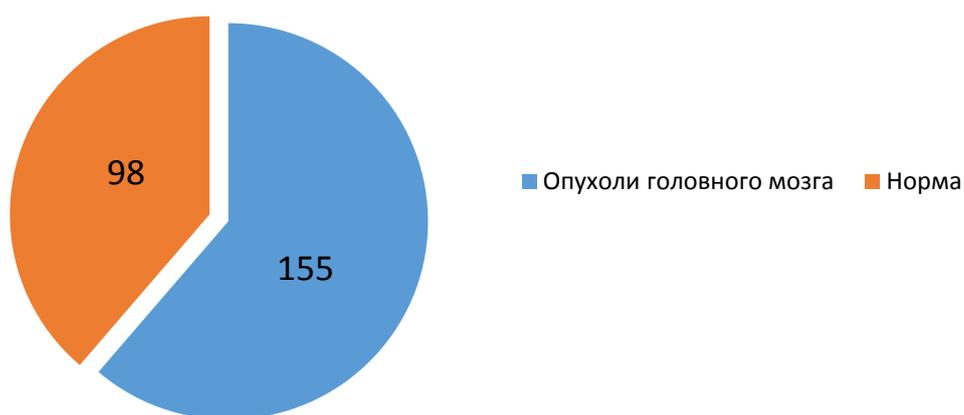


Рис. 25. Распределение исходных данных по размерам классов.

Данные для выявления опухолей головного мозга взяты из открытого источника, сайта [kaggle.com](https://www.kaggle.com). Это общедоступная веб-платформа, на которой пользователи и организации могут публиковать свои наборы данных, изучать и создавать модели, а также взаимодействовать с другими специалистами по обработке данных и инженерами по машинному обучению. Эта система содержит открытые наборы данных и предоставляет облачные инструменты для обработки данных и машинного обучения.

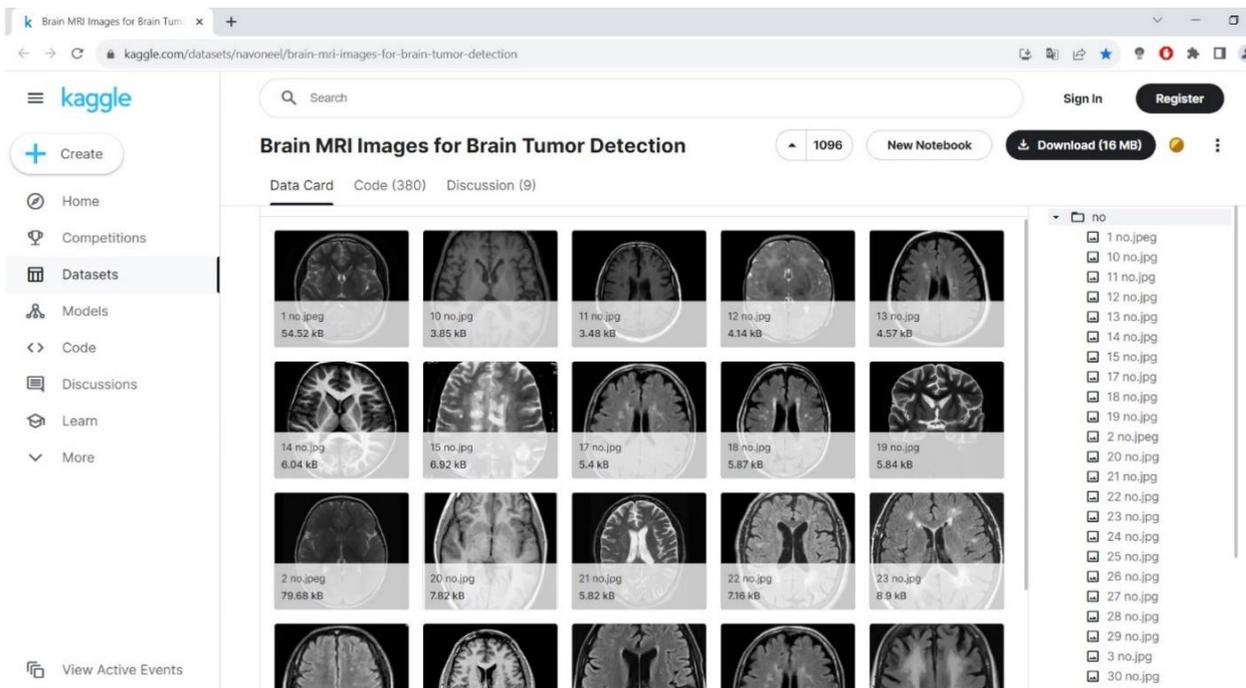
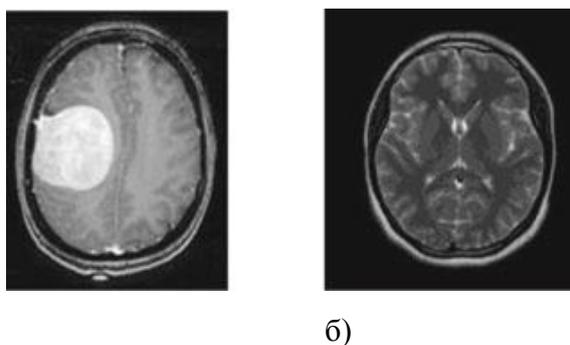


Рис. 26. Исходная база данных изображений МРТ головного мозга Brain MRI Images for Brain Tumor Detection на сайте kaggle.com.

Исходной базой данных МРТ-изображений головного мозга послужили база Brain MRI Images for Brain на сайте kaggle.com. Этот набор данных (см. Рис. 26) состоит из двух типов набора изображений: “Да” и “Нет”, который содержит 253 изображения МРТ головного мозга. Набор изображений “Да” содержит 155 изображений мозга с опухолями, а набор изображений “Нет” содержит 98 изображения мозга, не являющиеся опухолевыми.

Рис. 27 представляет собой пример из набора данных, содержащий изображения с опухолями и без опухолей.



а)

б)

Рис. 27. а) изображение с опухолью; б) изображение без опухоли.

Основные принципы сбора медицинских данных для разработки систем глубокого обучения таковы:

1. Анонимизация (удаление информации, характеризующей конкретного пациента, из последовательности обрабатываемых данных).
2. Структурирование данных – разделение обучающих данных на группы в соответствии с наилучшим образом спланированным дизайном базы данных.
3. Присвоение меток классов.
4. Верификация – подтверждение визуальных диагностических данных морфологическими или другими методами для минимизации неточностей при обучении систем глубокого обучения.
5. Патологическая маркировка – обзор интересующей области на изображении, выделение контура.

2.3. Процесс обучения алгоритма

Нейронные сети обучаются путем первичной обработки больших наборов предварительно размеченных или немаркированных данных. Основываясь на этих примерах, сеть может точно обрабатывать входные данные, которые ранее не были ей известны. Контролируемое обучение часто используется при распознавании изображений. Искусственные нейронные сети снабжаются помеченными наборами данных, которые заранее дают правильный ответ. Нейронные сети постепенно накапливают знания из этих наборов данных. Далее, сеть делает предположения об изображениях, которые она никогда ранее не обрабатывала.

В процессе обучения алгоритма в программу загружаются исходные МРТ-изображения головного мозга (с наличием опухолей и без них). Весь набор изображений обрабатывается с целью извлечения атрибутов, то есть

характерных признаков изображений. Для этой цели мы используем программный модуль Image Embedding (встраивание изображения), Рис. 28.

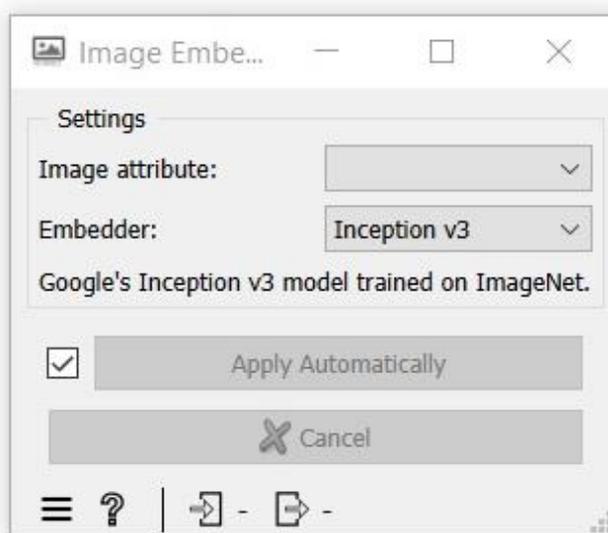


Рис. 28. Модуль Image Embedding (встраивание изображения) в среде Orange Data Mining.

В нём можно выбрать определенную сеть, которая является наиболее предпочтительной для выполнения конкретного исследования (Inception v3, VGG-16, VGG-19, SqueezeNet или другие). Выбор был сделан в пользу сети Inception v3, так как она даёт хорошие результаты в задачах обработки изображений (см. раздел 1.1).

Inception-v3 – это 48-слойная модель свёрточной нейронной сети с глубоким предварительным обучением и, как показано в уравнении 2.1, она способна изучать и распознавать сложные паттерны и особенности на медицинских изображениях.

$$\begin{aligned}
A &= \begin{bmatrix} A_{(1,1)} & \dots & A_{(1,N)} \\ A_{(2,1)} & \dots & A_{(2,N)} \\ A_{(M,1)} & \dots & A_{(M,N)} \end{bmatrix} * \begin{bmatrix} B_{(1,1)} & \dots & B_{(1,N)} \\ B_{(2,1)} & \dots & B_{(2,N)} \\ B_{(M,1)} & \dots & B_{(M,N)} \end{bmatrix} \\
&= \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} A_{(M-1)(N-j)} B_{(i+1)(j+1)} \quad .
\end{aligned} \tag{2.1}$$

Одной из ключевых особенностей Inception v3 является её способность масштабироваться до больших наборов данных и обрабатывать изображения различных размеров и разрешений. Это важно в области медицинской визуализации, где изображения могут сильно различаться по размеру, разрешению и качеству. Как правило, модуль Inception включает в себя одно максимальное объединение и три свёртки различного размера [63]. После операции свертки канал агрегируется для сетевого вывода предыдущего уровня, а затем выполняется нелинейное объединение [55].

После выбора в модуле Image Embedding нейронной сети Inception v3, и запуска данной нейронной сети в работу происходит загрузка изображений и передача их для обработки на сервере компании Google LLC. После завершения процесса обработки нейронная сеть возвращает нам атрибуты каждого изображения МРТ в табличном формате. Атрибуты изображений (n0...n2048) служат теми исходными данными, которые будут в дальнейшем передаваться классификаторам для определения категории изображения.

	category	image name	image	size	width	height	n0	n1	n2	n3
1	no	1 no	no\1 no.jpeg	54521	630	630	0.0560167	0.13427	0.32431	0.157521
2	no	10 no	no\10 no.jpg	3848	173	201	0.179086	0.148738	0.0225835	0.35221
3	no	11 no	no\11 no.jpg	3475	300	168	0.20592	0.252682	0.0805907	0.493382
4	no	12 no	no\12 no.jpg	4142	275	183	0.0397475	0.0544977	0.124545	0.341861
5	no	13 no	no\13 no.jpg	4570	300	168	0.240901	0.138043	0.0813261	0.369681
6	no	14 no	no\14 no.jpg	6039	177	197	0.17782	0.432347	0.221648	0.59562
7	no	15 no	no\15 no.jpg	6924	232	217	0.352954	0.291513	0.232953	0.817477
8	no	17 no	no\17 no.jpg	5400	218	231	0.19356	0.181161	0.042661	0.464604
9	no	18 no	no\18 no.jpg	5868	228	221	0.181594	0.317352	0.148092	0.209889
10	no	19 no	no\19 no.jpg	5843	200	200	0.22998	0.121199	0.785566	0.556991
11	no	2 no	no\2 no.jpeg	79678	630	630	0.0360797	0.157793	0.414817	0.295968
12	no	20 no	no\20 no.jpg	7815	194	259	0.126076	0.817632	0.247532	0.182692
13	no	21 no	no\21 no.jpg	5816	225	225	0.133299	0.344751	0.454178	0.211334
14	no	22 no	no\22 no.jpg	7163	207	243	0.363058	0.176466	0.374215	0.304997
15	no	23 no	no\23 no.jpg	8899	208	242	0.171549	0.246544	0.151303	0.341552
16	no	24 no	no\24 no.jpg	5882	235	214	0.684423	0.0884995	0.0849363	0.296844
17	no	25 no	no\25 no.jpg	7882	232	217	0.0882958	0.822849	0.305694	0.307942
18	no	26 no	no\26 no.jpg	7313	200	252	0.412907	0.127003	0.0878032	0.198867
19	no	27 no	no\27 no.jpg	5400	218	231	0.19356	0.181161	0.042661	0.464604
20	no	28 no	no\28 no.jpg	6113	201	251	0.145858	0.366158	0.0317709	0.252972
21	no	29 no	no\29 no.jpg	6401	215	234	0.198039	0.413614	0.258808	0.109993
22	no	3 no	no\3 no.jpg	5931	225	225	0.279621	0.0250204	0.0997323	0.808295
23	no	30 no	no\30 no.jpg	9339	208	242	0.111212	0.184732	0.0626503	0.444504
24	no	31 no	no\31 no.jpg	7119	200	252	0.503505	0.176195	0.0266491	0.177215
25	no	32 no	no\32 no.jpg	5961	225	225	0.254774	0.395585	0.0343892	0.164744
26	no	33 no	no\33 no.jpg	5134	236	213	0.305675	0.166589	0.0385448	0.179651
27	no	34 no	no\34 no.jpg	4386	150	198	0.230445	0.272648	0.0366481	0.250949
28	no	35 no	no\35 no.jpg	6021	225	225	0.323173	0.223392	0.140975	0.196146
29	no	36 no	no\36 no.jpg	5114	228	221	0.212061	0.127197	0.200554	1.00906
30	no	37 no	no\37 no.jpg	6770	225	225	0.0536798	0.667171	0.423798	0.312275
31	no	38 no	no\38 no.jpg	7371	201	251	0.276981	0.123991	0.177982	0.488689
32	no	39 no	no\39 no.jpg	7079	225	225	0.0934261	0.329432	0.238538	0.525419
33	no	4 no	no\4 no.jpg	6399	201	250	0.133284	0.288884	0.288452	0.229292
34	no	40 no	no\40 no.jpg	5758	225	225	0.440663	0.385774	0.12354	0.15203
35	no	41 no	no\41 no.jpg	5758	225	225	0.440663	0.385774	0.12354	0.15203

Рис. 29. Атрибуты изображений МРТ.

Каждое изображение переведено в атрибуты и представлено в табличном формате. Рис. 29 иллюстрирует результат работы модуля Image Embedding. Обработка изображений для получения атрибутов полностью скрыта от пользователя, эта задача целиком лежит на нейросети, что существенно облегчает задачу исследования. Далее, модуль Image Embedding подключается к соответствующим модулям классификации, выбранным исследователем (логистическая регрессия, машина опорных векторов, дерево решений и т.д.), и передаёт в них полученные данные.

Для оценки работы алгоритмов классификации подключаем виджет Test and Score (см. Рис. 30). В процессе тестирования алгоритма этот виджет представляет таблицу, содержащую различные показатели эффективности классификатора, такие как точность классификации по соответствующему методу и метрика площади под кривой (*англ.* area under the curve, AUC). Кроме того, он выводит результаты оценки, используемые для анализа производительности классификатора в других виджетах, например, ROC-анализ и матрица путаницы.

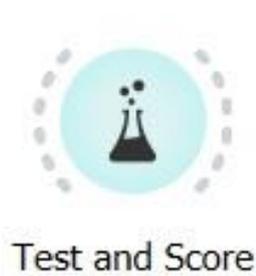


Рис. 30. Модуль Test and Score (тест и оценка) средства интеллектуального анализа данных Orange Data Mining.

Качество используемой модели оценивается при помощи методов перекрестной проверки (кросс-валидации). Перекрестная проверка – это метод, предназначенный для оценки качества модели, который широко используется в машинном обучении. Он позволяет сравнивать различные модели и выбирать наилучшую для конкретной задачи. Метод основан на разбиении исходного набора данных на k приблизительно равных блоков, например, $k = 5$. Затем, с помощью $k - 1$, или четырёх блоков, модель обучается, а 5-й блок используется для тестирования. Этот шаг повторяется k раз, и на каждом проходе выбирается новый блок для проверки, а на оставшихся блоках выполняется обучение. Принцип работы данного метода изображён на Рис. 31.



Рис. 31. Принцип работы метода кросс-валидации.

Test and Score - Orange

Cross validation
 Number of folds: 20
 Stratified
 Cross validation by feature

 Random sampling
 Repeat train/test: 100
 Training set size: 95 %
 Stratified

Evaluation results for target (None, show average over classes)

Model	AUC	CA	F1	Prec	Recall	MCC
Logistic Regression	0.957	0.897	0.897	0.898	0.897	0.784
Tree	0.765	0.794	0.796	0.799	0.794	0.575
SVM	0.953	0.905	0.904	0.908	0.905	0.800
kNN	0.927	0.759	0.728	0.811	0.759	0.509
Naive Bayes	0.919	0.850	0.851	0.856	0.850	0.694
Random Forest	0.951	0.870	0.868	0.871	0.870	0.723
Neural Network	0.960	0.917	0.917	0.917	0.917	0.824

Рис. 32. Результаты работы модуля Test and score (тест и оценка).

2.4. Прогностическая модель распознавания МРТ изображений

Перейдём к рассмотрению предлагаемой прогностической модели (Рис. 33).

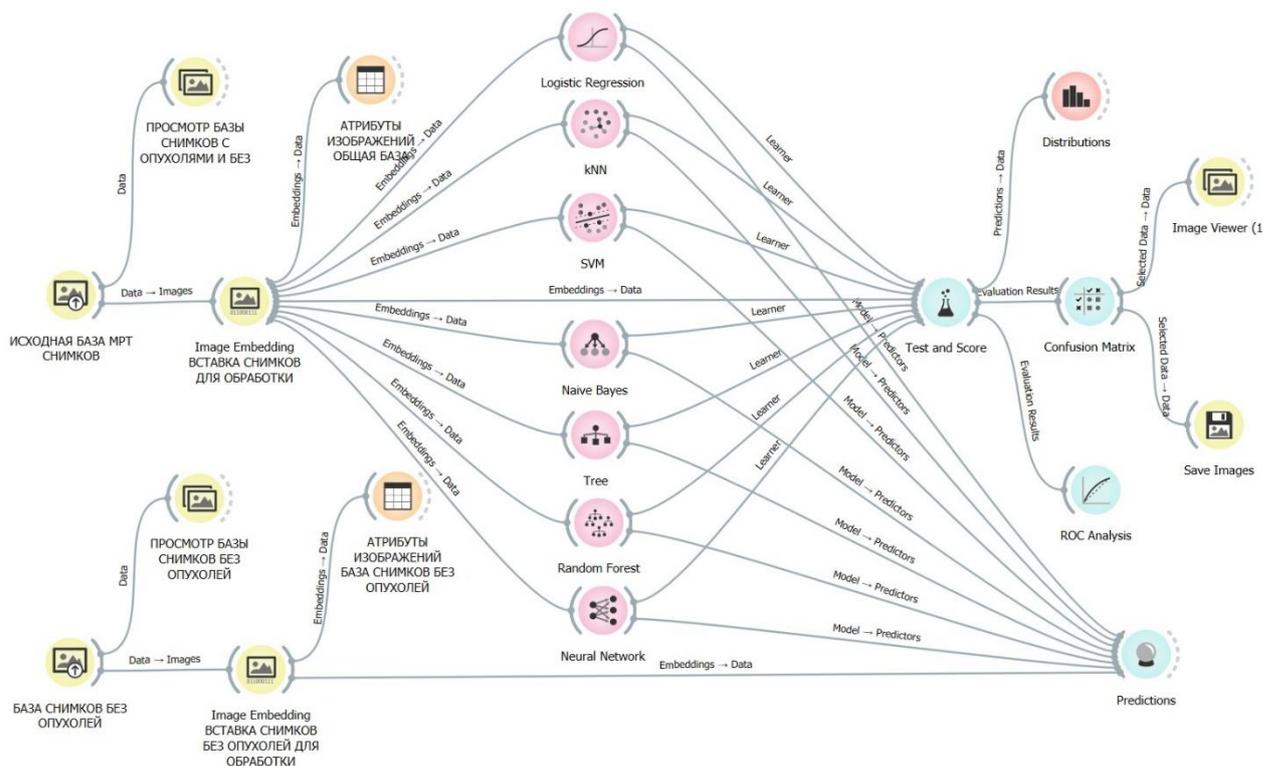


Рис. 33. Предлагаемый алгоритм распознавания МРТ-изображений.

В качестве тестового набора снимков был использован набор изображений, не содержащий снимков с опухолями. Он аналогичным образом обрабатывается модулем Image Embedding. В модуле Image Embedding происходит обработка всех изображений (с новообразованиями и без них) и выделяются атрибуты изображений для последующей классификации. Далее полученные атрибуты передаются в модуль Predictions (предсказания).



Predictions

Рис. 34. Модуль Predictions программы интеллектуального анализа данных Orange Data Mining.

Виджет Predictions получает набор данных и один или несколько предикторов. Он выводит данные и прогнозы в разрезе классификаторов. Результат работы данного модуля мы можем увидеть в таблице на Рис. 35. В таблице видно, насколько точно были сделаны выводы об отсутствии или наличии опухолей на снимках, то есть в какую категорию определил соответствующее изображение МРТ каждый классификатор.

	Tree	Logistic Regression	SVM	kNN	Naive Bayes	Random Forest	Neural Network
1	no	no	no	no	no	no	no
2	no	no	no	no	no	no	no
3	no	no	no	no	no	no	no
4	no	no	no	no	no	no	no
5	no	no	no	no	no	no	no
6	no	no	no	no	no	no	no
7	no	no	no	yes	yes	no	no
8	no	no	no	no	no	no	no
9	no	no	no	no	no	no	no
10	no	no	no	no	no	no	no
11	no	no	no	no	no	no	no
12	no	no	no	no	no	no	no
13	no	no	no	no	no	no	no
14	no	no	no	no	no	no	no
15	no	no	no	no	no	no	no
16	no	no	no	yes	no	no	no
17	no	no	no	no	no	no	no
18	no	no	no	no	no	no	no
19	no	no	no	no	no	no	no
20	no	no	no	yes	no	no	no
21	no	no	no	no	no	no	no
22	no	no	no	no	no	yes	no
23	no	no	no	yes	no	no	no
24	no	no	no	no	no	no	no
25	no	no	no	yes	no	no	no
26	no	no	no	yes	no	no	no
27	no	no	no	no	no	no	no
28	no	no	no	no	no	no	no
29	no	no	no	no	no	no	no
30	no	no	no	no	no	no	no
31	no	no	no	no	no	no	no
32	no	no	no	no	no	no	no

Рис. 35. Результат работы программного модуля Predictions.

2.5. Полученные результаты и оценка модели

Для оценки работы предложенной модели используем матрицу путаницы (confusion matrix) и кривую операционной функции (ROC-кривая). Матрица путаницы – это широко используемый инструмент оценки в области машинного обучения, особенно в контексте алгоритмов классификации. Это таблица, которая обобщает производительность классификатора, помогая визуализировать точность модели, показывая количество правильных и неправильных прогнозов, сделанных моделью. Матрица путаницы – это табличное представление производительности моделей классификации. Изучая матрицу путаницы, мы можем увидеть, какие классы модель предсказывает точно, а какие нет. Эта информация полезна для повышения производительности классификатора, поскольку позволяет нам определить области, которые могут нуждаться в дальнейшей оптимизации или тонкой настройке. В дополнение к визуализации матрица путаницы также позволяет нам рассчитать ряд показателей производительности. Эти метрики обеспечивают более количественный способ оценки производительности классификатора и могут быть полезны для сравнения различных моделей или для отслеживания хода разработки модели. В целом, матрица путаницы является полезным инструментом для оценки производительности алгоритма классификации и определения областей, требующих улучшения.

Преимущества использования матрицы путаницы:

- подробная разбивка производительности модели;
- возможность расчёта несколько показателей производительности;
- может использоваться для оценки нескольких классификаторов.

Матрица путаницы состоит из четырех блоков: истинноположительные (TP), ложноположительные (FP), истинно отрицательные (TN) и ложноотрицательные (FN) результаты. Эти термины относятся к прогнозам,

сделанным алгоритмом классификации, и определяются следующим образом:

– истинные положительные результаты (TP): правильно предсказанные классификатором как положительные;

– ложноположительные (FP): ошибочно предсказанные классификатором как положительные. Продолжая пример со спамом по электронной почте, ложным срабатыванием будет электронное письмо, которое не является спамом, но ошибочно определено классификатором как спам;

– истинные отрицательные (TN): это экземпляры, которые были правильно предсказаны классификатором как отрицательные. В примере со спамом по электронной почте истинно отрицательным будет электронное письмо, которое правильно предсказано как не спам;

– ложноотрицательные результаты (FN): это случаи, которые были ошибочно предсказаны классификатором как отрицательные. Примером ложноотрицательного результата в примере со спамом по электронной почте может быть электронное письмо, которое является спамом, но классификатор неправильно определил его как не спам.

		Predicted class	
		True	False
True class	True	TP	FN
	False	FP	TN

Рис. 36. Матрица путаницы для бинарной классификации.

Вместе эти четыре компонента (Рис. 36) образуют матрицу путаницы, которая обеспечивает подробную разбивку прогнозов, сделанных классификатором, и позволяет нам оценить производительность модели.

Эти результаты дают нам понимание производительности и полезны для расчета точности, достоверности, полноты и кривой AUC-ROC.

Точность (accuracy) - метрика для исследования сбалансированного набора данных:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad . \quad (2.2)$$

В случае несбалансированного набора данных используются другие варианты. В этом случае точность рассчитывается следующим образом:

Точность (precision) - это доля правильно распознанных положительных образцов из всех распознанных как положительный образец:

$$Precision = \frac{TP}{TP + FP} \quad . \quad (2.3)$$

Отзыв (recall) – это доля правильно распознанных положительных образцов из всех образцов:

$$Recall = \frac{TP}{TP + FN} \quad . \quad (2.4)$$

Чтобы найти баланс между *Accuracy* и *Precision*, можно использовать показатель *F1*, который дает гармоническое среднее между ними. Формула для вычисления показателя *F1*:

$$F1 = \frac{TP}{TP + FN + 2 * FP} \quad . \quad (2.5)$$

MCC (англ. Matthews Correlation Coefficient) – коэффициент корреляции Мэтьюса:

$$MCC = \frac{TP*TN - FP*FN}{\sqrt{(TP+FP)*(TP+FN)*(TN+FP)*(TN+FN)}} \quad (2.6)$$

Коэффициент корреляции Мэтьюса - это коэффициент корреляции между фактической биномиальной классификацией, полученной с помощью модели, и прогнозируемой биномиальной классификацией. Он варьируется от -1 до 1 . $MCC = 1$ указывает на идеальную классификацию, модель с $MCC = 0$ соответствует случайному предсказателю. Коэффициент $MCC = -1$ указывает на полное расхождение между фактами и прогнозами (то есть вместо положительных классов модель всегда предсказывает отрицательные классы, и наоборот). На практике классификатор не может одновременно обладать высокой прецизионностью и точностью. Увеличение отклика снизит точность, и наоборот. Таким образом, надо посмотреть, что действительно важно в задаче классификации, прежде чем выбирать то, что требуется минимизировать. Например, в задаче обнаружения рака обычно лучше классифицировать здорового пациента как больного раком, чем классифицировать больного раком как здорового.

Рассмотрим матрицу путаницы в случае предлагаемой модели на примере машины опорных векторов (см. Рис. 37). Ожидаемые значения (выходные данные системы) представлены по оси X , а по оси Y представлены истинные. Как показано на рис.39, из 98 неопухолевых МРТ изображений, 78 классифицируются правильно, как изображения, не содержащие опухоли, а 20 неопухолевых изображений неправильно классифицируются как “да” или “целевая группа” класса опухолей. 150 из 155 МРТ изображений были правильно классифицированы как целевые классы опухолей, в то время как 5 из них были ошибочно отнесены к неопухолевым целевым классам. На основе матрицы путаницы установлено, что точность предложенной модели составляет около 91%. Однако, вариабельность анатомии головного мозга характеризуется разной структурой. Сложности визуализации малозаметных

новообразований обуславливают появление ошибок, особенно когда паталогические образования перекрываются с другими структурами мозга.

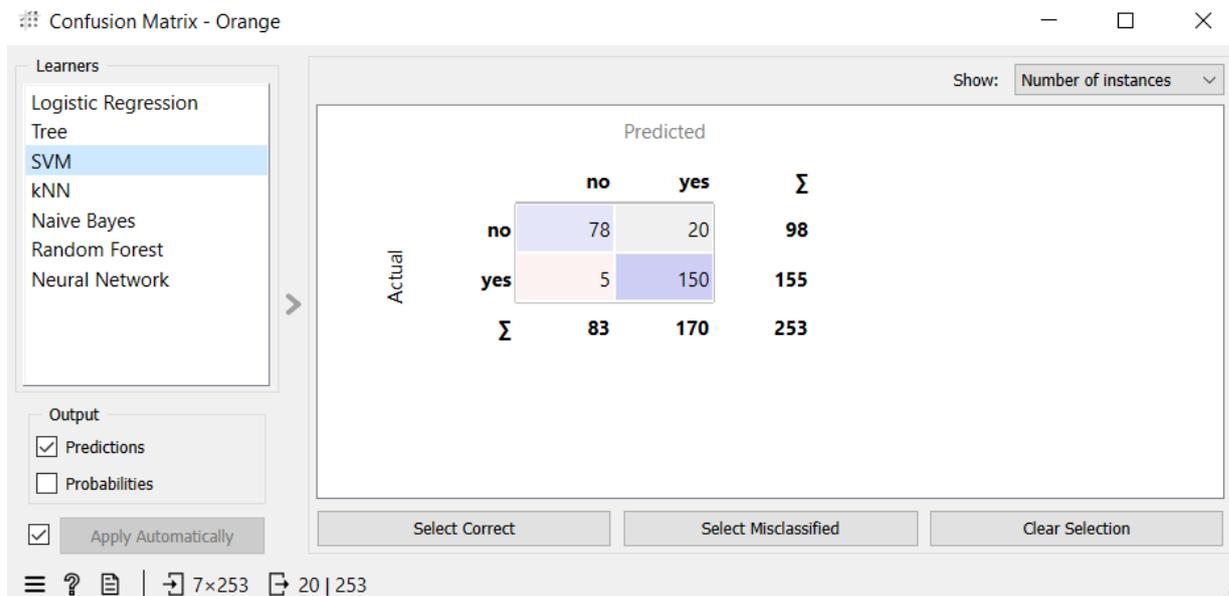


Рис. 37. Матрица путаницы по результатам работы классификатора данных SVM.

Еще одним средством визуализации результатов работы предлагаемой модели и её оценки является кривая операционной функции (т.н. ROC-кривая). Представленная на Рис. 38 кривая отображает уровень ложноположительных результатов по оси X до истинно положительных по оси Y. Чем ближе кривая проходит к левой границе, и чем выше верхняя граница пространства ROC, тем точнее классификатор.

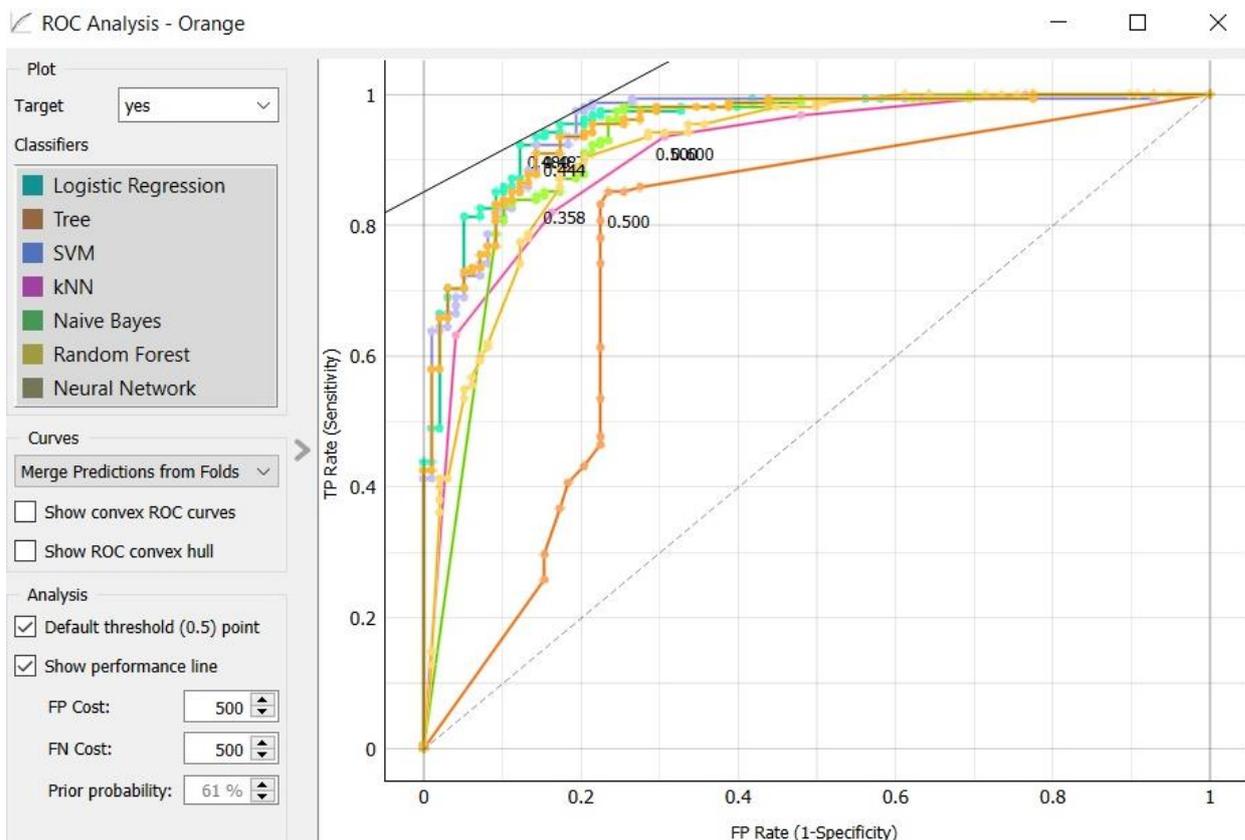


Рис. 38. Кривая операционной функции (ROC-кривая).

График ROC-кривой (см. Рис. 38) рассчитывает отношение числа правильно распознанных случаев к числу неправильных. Расчет производится следующим образом: последовательно берутся данные, и в них вычисляется это отношение. В определённый момент отношение становится константой.

Смысл значения AUC – вероятность того, что случайно выбранному здоровому пациенту диагностируют рак, чем случайно выбранному больному. Мы видим, что дерево решений (раздел 1.6) относится к “слабому” классификатору. Напротив, алгоритмы нейронной сети (раздел 1.1), случайного леса (раздел 1.7) и k -ближайших соседей (раздел 1.3) обладают большой прогностической ценностью.

Полученные в исследовании значения площади под кривой (AUC) варьируются от 0,765 до 0,96. Таким образом, применение глубинного

обучения позволяет проводить дифференциальную диагностику очаговых образований в головном мозге с высокой степенью достоверности.

2.6. Выводы по главе 2

Неоспорим факт, что в результате работы алгоритмов могут возникать ошибки в силу различного биологического поведения опухоли (раздел 2.4). Автором работы были проанализированы как ложноположительные, так и ложноотрицательные ответы системы разных алгоритмов классификации данных (разделы 1.1-1.8). Полученные значения показателей информативности алгоритмов представлены в таблице 1.

Таблица 1. Показатели информативности разрабатываемого алгоритма.

Метод классификации	AUC	CA	F1	Precision	Recall	MCC
Логистическая регрессия (Logistic regression)	0,957	0,897	0,897	0,898	0,897	0,784
Дерево решений (Decision Tree)	0,765	0,794	0,796	0,799	0,794	0,575
Машина опорных векторов (SVM)	0,953	0,905	0,904	0,908	0,905	0,800
к-ближайших соседей (KNN)	0,927	0,759	0,728	0,811	0,759	0,509
Наивный Байес (Naïve Bayes)	0,919	0,850	0,851	0,856	0,850	0,694
Случайный лес (Random Forest)	0,951	0,870	0,868	0,871	0,870	0,723
Нейросеть (Neural network)	0,960	0,915	0,917	0,916	0,917	0,824

AUC (*англ.* Area Under Curve, площадь под кривой), рассчитывается как отношение TPR/FPR (true positive result / false positive result)

CA (*англ.* Classification Accuracy) – метрика точности, формула расчёта 2.2

F1 – гармоническое среднее между точностью и прецизионностью, формула расчёта 2.5

Precision (*англ.* Precision, точность) – метрика точности, формула расчёта 2.3

Recall (*англ.* Recall, отзыв) – формула расчёта 2.4

MCC (*англ.* Matthews Correlation Coefficient) – коэффициент корреляции Мэтьюса, формула расчёта 2.6

Анализ информации, представленной на приведенных выше рисунках и таблицах, позволяет сформулировать выводы о принципах адаптации методов интеллектуального анализа данных к задачам распознавания медицинских изображений головного мозга.

Классификатор, основанный на глубокой нейронной сети, показал выгодные показатели классификации изображений и наилучшие показатели качества результатов.

Прогностическая модель основана на простой свёрточной архитектуре нейронной сети и проста в освоении. Предлагаемая модель может служить дополнительным инструментом для врачей при диагностике опухолей головного мозга. Внедряя алгоритмы компьютерного зрения в повседневную работу врача, становится возможным быстрее проводить обследование, ставить диагноз и начинать лечение.

Заключение

В рамках решения поставленных задач, были получены следующие основные результаты:

1. Предложена модель построения модульного алгоритма для поддержки принятия врачебных решений.
2. На основе глубинного обучения выполнена классификация МРТ-изображений головного мозга.
3. Предлагаемая модель может быть обобщена для Интернет-приложения с интеллектуальным агентом, что особенно актуально в условиях ограниченного числа врачей-специалистов.
4. Разработанный алгоритм обладает точностью до 91,7% и величиной AUC до 0,96.

В представленной работе средства интеллектуального анализа данных были использованы для классификации медицинских данных. Предлагаемая модель может использовать набор данных МРТ-изображений головного мозга в качестве входных данных для классификации изображений и обнаружения опухолей на изображениях. Был предложен подход к распознаванию опухолей головного мозга, и эта модель позволяет различать опухолевые и неопухолевые изображения. В будущем эта модель может быть использована в сочетании с различными МРТ-изображениями для создания диагностической системы для диагностики других заболеваний головного мозга, таких как деменция, инсульт, болезнь Альцгеймера и болезнь Паркинсона. Алгоритм может быть модифицирован и для диагностики прочих видов новообразований. Результаты этой работы могут принести пользу всем заинтересованным сторонам (врачам, исследователям, пациентам) и способствовать развитию интеллектуального анализа данных в сфере здравоохранения в целом. Можно утверждать, что будущее

медицинской информатики выиграет от экспоненциально увеличивающегося объема цифровых данных в здравоохранении, применения и совершенствования инструментов интеллектуального анализа данных.

Список литературы

1. Абдулракеб А.Р.А., Сушкова Л.Т., Лозовская Н.А. Обзор методов сегментации опухолей на МРТ-изображениях головного мозга / Абдулракеб А.Р.А. // Прикаспийский журнал: управление и высокие технологии. – 2015. – №1 (29). – С. 192-208. 3.
2. Анализ данных / М.Ю. Архипова, В.П. Сиротин, В.С. Мхитарян [и др.]. - М.: Изд-во Юрайт, 2016. – 491 с.
3. Благирев, А.П. Big data простым языком / А.П. Благирев. - М.: "Издательство АСТ", 2019. - 256 с.
4. Бринк, Х. Машинное обучение / Х. Бринк, Дж. Ричардс, М. Феверолф. - СПб.: "Питер", 2017. - 336 с.
5. Вьюгин, В.В. Математические основы теории машинного обучения и прогнозирования / В.В. Вьюгин. – М.: Издательство МЦНМО, 2013. – 304 с.
6. Гифт, Н. Прагматичный ИИ. Машинное обучение и облачные технологии / Н. Гифт. - СПб.: "Питер", 2019. – 306 с.
7. Грас, Д. Data Science. Наука о данных с нуля / Д. Грас. – СПб.: «БХВ-Петербург», 2021. – 416 с.
8. Каприн А.Д., Старинский В.В., Шахзадова А.О. Злокачественные новообразования в России в 2020 году (заболеваемость и смертность) – М.: МНИОИ им. П.А. Герцена – филиал ФГБУ «НМИЦ радиологии» Минздрава России, – 2021. – 252 с. ISBN 978-5-85502-268-1.
9. Кудрейко А.А., Мигунов В.В. Глубинное обучение в задаче распознавания новообразований головного мозга // сборник научных статей XIII Международной научно-практической конференции “Актуальные аспекты развития науки и общества в эпоху цифровой трансформации”. – 2024 г. – с.170-177. – DOI 10.34755/IROK.2024.60.84.006.

10. Култыгин, О.П. Использование искусственного интеллекта – реальность и перспективы / О.П. Култыгин // Journal of applied informatics. – 2019. – Vol. 14. - DOI: org/10.24411/1993-8314-2019-10010.
11. Лаутербур, П.С. (1973). "Формирование изображения путем индуцированных локальных взаимодействий: примеры использования ядерного магнитного резонанса". Nature. 242 (5394):190–191. Bibcode:1973. Natur.242.190L. doi:10.1038/242190a0. S2CID 4176060.
12. Лекун Ян. Как учится машина. Революция в области нейронных сетей и глубокого обучения. (Библиотека Сбера: Искусственный интеллект). — М.: Интеллектуальная литература, 2021. — ISBN 978-5-907394-29-2.
13. Марр, Д. Зрение. Информационный подход к изучению представления и обработки зрительных образов / Д. Марр // М.: Радио и связь. – 1987. – 400 с.
14. Мерков, А.Б. Распознавание образов: Введение в методы статистического обучения / А.Б. Мерков. – М.: Едиториал УРСС, 2011. – 254 с.
15. Нархид, Н. Apache Kafka. Поточковая обработка и анализ данных / Н. Нархид, Г. Шапира, Т. Палино. - СПб.: «Питер», 2019. – 320 с.
16. Николенко, С. Глубокое обучение. Погружение в мир нейронных сетей / С. Николенко, А. Кадурин, Е. Архангельская. - СПб.: «Питер», 2018. – 479 с.
17. Паттерсон, Д. Глубокое обучение с точки зрения практики / Д. Паттерсон, А. Гибсон. - М.: ДМК Пресс, 2018. – 418 с.
18. Потапов, А.С. Распознавание образов и машинное восприятие / А.С. Потапов. – СПб.: Политехника, 2007. – 547 с.
19. Рашид, Т. Создаем нейронную сеть / Т. Рашид. - СПб.: ООО "Альфа-книга", 2017. - 272 с.
20. Сергеев, Н. Аналитика и Data Science / Н. Сергеев. – М.: Издательские решения, 2019. – 330 с.

21. Флах, П. Машинное обучение. Найка и искусство построения алгоритмов, которые извлекают знания из данных / П. Флах. - М.: ДМК Пресс, 2015. – 400 с.
22. Abdusalomov AB, Mukhiddinov M, Whangbo TK. Brain tumor detection based on deep learning approaches and magnetic resonance imaging. *Cancers*. 2023;15(16):4172.
23. An iterative model of the generalized Cauchy process for predicting the remaining useful life of lithium-ion batteries / G. Hong, W. Song, Y. Gao, A. Kudreyko [et al.] // *Measurement*. – 2022. – Vol. 187. – DOI: [org/10.1016/j.measurement.2021.110269](https://doi.org/10.1016/j.measurement.2021.110269).
24. Analyzing COVID-19 Dataset through Data Mining Tool “Orange” / U. Thange, V.K. Shukla, R. Punhani, W. Grobbelaar // *IEEEExplore*. – 2021. – DOI: [org/10.1109/ICCAKM50778.2021.9357754](https://doi.org/10.1109/ICCAKM50778.2021.9357754).
25. Andriessse, D. *Practical Binary Analysis* / D. Andriessse. - William Pollock, 2019. – 460 p.
26. Bellemare, A. *Building Event-Driven Microservices* / A. Bellemare. - O’Reilly Media, Inc., 2020. – 324 p.
27. Bolotsky A, Butler D, Dong C, et al. Two-dimensional materials in biosensing and healthcare: from in vitro diagnostics to optogenetics and beyond. *ACS nano*. 2019;13(9):9781-9810.
28. Bruce, P. *Practical statistics for data scientists* / P. Bruce, A. Bruce, P. Gedeck. - O’Reilly Media, Inc., 2020. – 363 p.
29. Canning, J. *Data structures & Algorithms in Python* / J. Canning, A. Broden, R. Lafore. - Addison-Wesley, 2017. – 1160 p.
30. Chetlen A.L., Chan T.L. [et al.] // *Addressing burnout in radiology*. – 2019. – 526.
31. Coudray, N., Ocampo, P.S., Sakellaropoulos, T., Narula, N., Snuderl, M., Fenyö, D., Moreira, A.L., Razavian, N. and Tsirikos, A., 2018. Classification and mutation prediction from non–small cell lung cancer histopathology images using deep learning. *Nature medicine*, 24(10), pp.1559-1567.

32. Danilov GV, Shifrin MA, Kotik KV, Ishankulov TA, Orlov YN, Kulikov AS, Potapov AA. Artificial intelligence in neurosurgery: A systematic review using topic modeling. Part I: Major research areas. *Sovremennye Tehnologii v Medicine*. 2020;12(5):106-112. <https://doi.org/10.17691/stm2020.12.5.12>.
33. Danilov GV, Shifrin MA, Kotik KV, Ishankulov TA, Orlov YN, Kulikov AS, Potapov AA. Artificial Intelligence Technologies in Neurosurgery: a Systematic Literature Review Using Topic Modeling. Part II: Research Objectives and Perspectives. *Sovremennye Tehnologii v Medicine*. 2021;12(6):111-118.. <https://doi.org/10.17691/stm2020.12.6.12>.
34. Data Mining for Business analytics / G. Shmueli, P.C. Bruce, P. Gedeck, N.R. Patel. - John Wiley & Sons, Inc., 2020. – 607 p.
35. Democratized image analytics by visual programming through integration of deep models and small-scale machine learning / P. Godec, M. Pancur, N. Ilenic [et al.] // *Nature Communications*. – 2019. – [Doi.org/nature.com/articles/s41467-019-12397-x](https://doi.org/nature.com/articles/s41467-019-12397-x).
36. Fookes C., Lin F., Chandran V. Evaluation of image resolution and super-resolution on face recognition performance // *Journal of Visual Communication and Image Representation*, V.23, 2012. P.75-93.
37. Fractional Lévy stable motion: Finite difference iterative forecasting model / H. Liu, W. Song, M. Li, A. Kudreyko [et al.] // *Chaos, Solitons & Fractals*. – 2020. – Vol. 133. – DOI: [org/10.1016/j.chaos.2020.109632](https://doi.org/10.1016/j.chaos.2020.109632).
38. Fukushima, Neocognitron (1980). "A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position". *Biological Cybernetics*. 36 (4): 193–202. doi:10.1007/bf00344251.
39. Goswami, T. *Statistical Modeling in Machine Learning* / T. Goswami, G.R. Sinha. - Academic Press, 2022. – 398 p.
40. Han, J. *Data Mining Concepts and Techniques* / J. Han, M. Kamber, J. Pei. - Elsevier Publishers, 2012. – 740 p.
41. Huyen, C. *Designing Machine Learning Systems* / C. Huyen. - O'Reilly Media, Inc., 2022. – 389 p.

42. Image classification on ImageNet [Электронный ресурс]: URL: <https://paperswithcode.com/sota/image-classification-on-imagenet> (дата обращения 01.05.2024).
43. ImageNet [Электронный ресурс]: URL: <https://paperswithcode.com/dataset/imagenet> (дата обращения: 01.05.2024).
44. Jordan, M. Pattern recognition and machine learning / M. Jordan, J. Kleinberg, B. Scholkorf. - Springer Science+Business Media, LLC, 2006. – 758 p.
45. Lambin P, Rios-Velazquez E, Leijenaar R, Carvalho S, van Stiphout RGPM, Granton P, Zegers CML, Gillies R, Boellard R, Dekker A, Aerts HJWL. Radiomics: Extracting more information from medical images using advanced feature analysis. *European Journal of Cancer*. 2012;48(4):441-446. <https://doi.org/10.1016/j.ejca.2011.11.036>.
46. Machine learning and data science / P. Agrawal, C. Gupta, A. Sharma [et al.]. - Scrivener Publishing, 2022. – 271 p.
47. Machine learning and wireless communications / Y.C. Eldar, A. Goldsmith, D. Gunduz, H.V. Poor. - Cambridge University Press, 2022. – 559 p.
48. McFaline-Figueroa JR, Lee EQ. Brain tumors. *The American journal of medicine*. 2018 Aug 1;131(8):874-82.
49. Mei S., Liu M., Kudreyko A., et al. Bendlet transform based adaptive denoising method for microsection images. *Entropy*. 2022;24(7):869.
50. Metsis, V. Spam Filtering with Naive Bayes - Which Naive Bayes? / V. Metsis, I. Androutsopoulos, G. Paliouras // DBLP. – 2006. – DOI: [org/researchgate.net/publication/221650814_Spam_Filtering_with_Naive_Bayes_-_Which_Naive_Bayes](https://doi.org/researchgate.net/publication/221650814_Spam_Filtering_with_Naive_Bayes_-_Which_Naive_Bayes).
51. Muller, A.C. Machine Learning with Python / A.C. Muller, S. Guido. - O'Reilly Media, Inc., 2016. – 340 p.
52. Multifractional and long-range dependent characteristics for remaining useful life prediction of cracking gas compressor / W. Song, S. Duan, E. Zio, A. Kudreyko // *Reliability Engineering & System Safety*. – 2022. – Vol. 225. – DOI: [org/10.1016/j.ress.2022.108630](https://doi.org/10.1016/j.ress.2022.108630).

53. Neural network design / M.T. Hagan, H.B. Demuth, M.H. Beale, O.D. Jesus. - PWS Publishers, 2014. – 1012 p.
54. Ogutu, J.O. Genomic selection using regularized linear regression models: ridge regression, lasso, elastic net and their extensions / J.O. Ogutu, T. Schulz-Streeck, H.-P. Piepho // BMS Proceedings. – 2012. – Vol. 6. – DOI: [org/bmcproc.biomedcentral.com/articles/10.1186/1753-6561-6-S2-S10](https://doi.org/10.1186/1753-6561-6-S2-S10).
55. Pan Y, Liu J, Cai Y, Yang X, Zhang Z, Long H, Zhao K, Yu X, Zeng C, Duan J, Xiao P, Li J, Cai F, Yang X and Tan Z (2023) Fundus image classification using Inception V3 and ResNet-50 for the early diagnostics of fundus diseases. *Front. Physiol.* 14:1126780. doi: 10.3389/fphys.2023.1126780.
56. Peker, M. Use of Orange Data Mining Toolbox for Data Analysis in Clinical Decision Making: The Diagnosis of Diabetes Disease / M. Peker, O. Özkaraca, A. Şaşar // Expert System Techniques in Biomedical Science Practice. – 2018. – P. 143-167. - DOI: [org/10.4018/978-1-5225-5149-2.ch007](https://doi.org/10.4018/978-1-5225-5149-2.ch007).
57. Pierson, L. Data Science for Dummies / L. Pierson. - John Wiley & Sons, Inc., 2017. – 329 p.
58. Prognosis and Treatment Prediction of Type-2 Diabetes Using Deep Neural Network and Machine Learning Classifiers / M. Kowsher, M.Y. Turaba, T. Sajed, M.M.M. Rahman // IEEEXplore. – 2020. – DOI: [org/10.1109/ICCIT48885.2019.9038574](https://doi.org/10.1109/ICCIT48885.2019.9038574).
59. Remaining useful life prediction for Lithium-ion batteries using fractional Brownian motion and Fruit-fly Optimization Algorithm / H. Wang, W. Song, E. Zio, A. Kudreyko // Measurement. – 2020. – Vol. 161. – DOI: [org/10.1016/j.measurement.2020.107904](https://doi.org/10.1016/j.measurement.2020.107904).
60. Sagheer S.V.M. and George, S.N., 2020. A review on medical image denoising algorithms. *Biomedical signal processing and control*, 61, p.102036.
61. Sharma K, Kaur A, Gujral S. Brain tumor detection based on machine learning algorithms. *International Journal of Computer Applications*. 2014;103(1).
62. Szegedy, Christian (2015). "Going deeper with convolutions". CVPR2015.

63. Ting D. S. W., Cheung C. Y. L., Lim G., Tan G. S. W., Quang N. D., Gan A., et al. (2017). Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes. *JAMA* 318 (22), 2211–2223. doi:10.1001/jama.2017.18152.
64. Type 2: Diabetes mellitus prediction using Deep Neural Networks classifier / P.B.M. Kumar, R.S. Perumal, R.K. Nadesh, K. Arivuselvan // *International Journal of Cognitive Computing in Engineering*. – 2020. – Vol. 1. – DOI: org/10.1016/j.ijcce.2020.10.002.
65. Vargas-Palacios, A., Sharma, N. & Sagoo, G.S. Cost-effectiveness requirements for implementing artificial intelligence technology in the Women’s UK Breast Cancer Screening service. *Nat Commun* 14, 6110 (2023). <https://doi.org/10.1038/s41467-023-41754-0>.

СПРАВКА

о результатах проверки текстового документа
на наличие заимствований

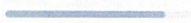
Башкирский государственный медицинский
университет

ПРОВЕРКА ВЫПОЛНЕНА В СИСТЕМЕ АНТИПЛАГИАТ.ВУЗ

Автор работы: Мигунов Владимир Валерьевич
Самоцитирование
рассчитано для: Мигунов Владимир Валерьевич
Название работы: ГЛУБИННОЕ ОБУЧЕНИЕ В ЗАДАЧЕ РАСПОЗНАВАНИЯ НОВООБРАЗОВАНИЙ В ГОЛОВНОМ МОЗГЕ
Тип работы: Выпускная квалификационная работа
Подразделение: ФГБОУ ВО Башкирский государственный медицинский университет МЗ РФ

РЕЗУЛЬТАТЫ

■ ОТЧЕТ О ПРОВЕРКЕ КОРРЕКТИРОВАЛСЯ: НИЖЕ ПРЕДСТАВЛЕНЫ РЕЗУЛЬТАТЫ ПРОВЕРКИ ДО КОРРЕКТИРОВКИ

СОВПАДЕНИЯ		18.39%	СОВПАДЕНИЯ		18.39%
ОРИГИНАЛЬНОСТЬ		67.6%	ОРИГИНАЛЬНОСТЬ		81.61%
ЦИТИРОВАНИЯ		14.01%	ЦИТИРОВАНИЯ		0%
САМОЦИТИРОВАНИЯ		0%	САМОЦИТИРОВАНИЯ		0%

ДАТА ПОСЛЕДНЕЙ ПРОВЕРКИ: 19.06.2024

ДАТА И ВРЕМЯ КОРРЕКТИРОВКИ: 19.06.2024 13:20

Структура документа: Проверенные разделы: библиография с.64-70, содержание с.2, основная часть с.3-63
Модули поиска: Цитирование; Переводные заимствования*; ИПС Адилет; Библиография; Перефразирование по Интернету (EN); Шаблонные фразы; СМИ России и СНГ; Коллекция НБУ; СПС ГАРАНТ: нормативно-правовая документация; Патенты СССР, РФ, СНГ; Диссертации НББ; Публикации eLIBRARY (переводы и перефразирования); Публикации РГБ; Переводные заимствования издательства Wiley; СПС ГАРАНТ: аналитика; Переводные заимствования по Интернету (EnRu); Переводные заимствования по коллекции Интернет в русском сегменте; Перефразированные заимствования по коллекции Интернет в английском сегменте; Переводные заимствования IEEE; Перефразирование по Интернету; Перефразирования по коллекции издательства Wiley; Издательство Wiley; Кольцо вузов (переводы и перефразирования); IEEE; Переводные

Работу проверил: Халитова Рита Камилевна

ФИО проверяющего

Дата подписи: 19.06.2024г.



Подпись проверяющего



Чтобы убедиться
в подлинности справки, используйте QR-код,
который содержит ссылку на отчет.

ФГБОУ ВО БГМУ
Министерства
научная библиотека

Ответ на вопрос об обнаруженном заимствовании
корректным, система отвечает на усмотрение проверяющего.
Представленная информация не подлежит использованию
в коммерческих целях.