



МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
федеральное государственное бюджетное образовательное учреждение
высшего образования
«РОССИЙСКИЙ ГОСУДАРСТВЕННЫЙ
ГИДРОМЕТЕОРОЛОГИЧЕСКИЙ УНИВЕРСИТЕТ»

Кафедра Информационные технологии и системы безопасности

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА
(Бакалавр)

На тему Классификация целей автономных подводных аппаратов на основе искусственного интеллекта

Исполнитель Мерц Владимир Евгеньевич
(фамилия, имя, отчество)

Руководитель кандидат технических наук, доцент
(ученая степень, ученое звание)

Грызунов Виталий Владимирович
(фамилия, имя, отчество)

«К защите допускаю»

Заведующий кафедрой

(подпись)

доктор технических наук
(ученая степень, ученое звание)

Бурлов Вячеслав Георгиевич
(фамилия, имя, отчество)

«__» _____ 2023 г.

г. Санкт-Петербург
2023 г.

СОДЕРЖАНИЕ

ВВЕДЕНИЕ	4
ГЛАВА 1. ОБЗОР ЛИТЕРАТУРЫ	6
1.1 Определение автономных подводных аппаратов и их виды.....	6
1.2 Структура и функции автоматизированных подводных аппаратов.....	7
1.3 Основные характеристики автономных подводных аппаратов	9
1.4 Цели и задачи, решаемые автономными подводными аппаратами, включая классификацию целей.....	10
1.5 Важность классификации целей для автономных подводных аппаратов .	17
1.6 Примеры задач и сценариев, где классификация целей является неотъемлемой частью операций подводных аппаратов	18
1.7 Основные принципы и подходы искусственного интеллекта в задачах классификации	19
1.8 Различные алгоритмы машинного обучения, используемые для классификации, включая нейронные сети.....	20
1.9 Существующие исследования и публикации, связанные с классификацией целей подводных объектов	21
1.10 Различные методы и подходы, применяемые для классификации подводных объектов на основе искусственного интеллекта.....	21
1.11 Преимущества, недостатки и результаты, достигнутые в этих исследованиях	22
ГЛАВА 2. МЕТОДОЛОГИЯ ИССЛЕДОВАНИЯ.....	24
2.1 Описание используемых данных.....	24
2.2 Подготовка данных для классификации.....	26
2.3 Архитектура и обучение нейронной сети.....	30
2.4 Обоснование выбранного метода классификации	31
ГЛАВА 3. РЕЗУЛЬТАТЫ.....	33
3.1 Оценка производительности разработанной нейронной сети	33
3.2 Анализ достигнутых результатов и их применимость в реальных условиях	34

ГЛАВА 4. ПРИМЕНЕНИЕ КЛАССИФИКАЦИИ ЦЕЛЕЙ АВТОНОМНЫХ ПОДВОДНЫХ АППАРАТОВ	36
4.1 Практические применения разработанной системы классификации	36
4.2 Выявление потенциальных областей применения и дальнейшие исследования	37
ЗАКЛЮЧЕНИЕ	39
ПРИЛОЖЕНИЯ.....	45

ВВЕДЕНИЕ

Автономные подводные аппараты являются важной составляющей современных исследований подводных ресурсов, океанографии, морской экологии и других областей. Классификация целей в подводной среде является важным фактором для определения и идентификации различных видов морской жизни, обнаружения подводных объектов и контроля уровня загрязнений. Применение искусственного интеллекта, особенно нейронных сетей, предоставляет новые возможности для улучшения точности и эффективности классификации подводных целей, что способствует развитию автономных подводных аппаратов.

Существующие методы классификации целей в подводной среде имеют свои ограничения, и дальнейшее развитие этой области является актуальной задачей. Использование искусственного интеллекта, основанного на нейронных сетях, открывает новые возможности для повышения точности и эффективности классификации целей. Разработка и применение подходящего метода классификации целей на основе искусственного интеллекта для автономных подводных аппаратов имеет большой потенциал для улучшения работы этих систем.

Целью данной работы является выбор подходящего метода классификации целей автономных подводных аппаратов, основанного на использовании искусственного интеллекта. Для достижения этой цели были сформулированы следующие задачи:

1. Провести обзор литературы и изучить существующие методы и подходы к классификации целей в подводной среде;
2. Анализировать преимущества и ограничения различных подходов и выбрать наиболее подходящий метод классификации целей для автономных подводных аппаратов;

3. Разработать модель классификации, основанную на выбранном методе, и провести эксперименты для оценки эффективности и точности модели;
4. Проанализировать результаты экспериментов и сделать выводы о применимости выбранного метода классификации целей для автономных подводных аппаратов.

Объектом исследования являются системы управления автономными подводными аппаратами. Предметом исследования являются способы классификации целей автономных подводных аппаратов на основе искусственного интеллекта.

Данная работа организована следующим образом. Вторая глава посвящена обзору литературы и представляет существующие методы и подходы к классификации целей в подводной среде. В этой главе рассматриваются различные методы машинного обучения, искусственные нейронные сети и другие алгоритмы, используемые для классификации подводных целей. Третья глава описывает разработанный подход к классификации целей на основе искусственного интеллекта, включая выбранный метод, используемые признаки и модель классификации. В этой главе также представлены подробности экспериментов и оценка эффективности разработанной модели. Четвёртая глава представляет результаты экспериментов, их анализ и обсуждение. В заключительной главе содержатся выводы, подводятся итоги исследования, а также рассматриваются возможности для дальнейших исследований в данной области.

ГЛАВА 1. ОБЗОР ЛИТЕРАТУРЫ

1.1 Определение автономных подводных аппаратов и их виды

Автономный подводный аппарат (АПА) — это роботизированное устройство, способное самостоятельно перемещаться под водой без оператора. В этот класс входят неавтономные подводные аппараты с дистанционным управлением, которые управляются и питаются от берега оператором (пилотом) или дистанционным управлением.

До недавнего времени АПА использовались только в ограниченных областях применения, в зависимости от доступных технологий. С развитием технологий обработки данных и высокоэффективных источников питания АПА стали более широко использоваться и развиваться. Питание АПА осуществляется от аккумуляторов или батарей другого типа. По весу и размеру АПА условно делятся на «большие», «средние» и «маленькие». Это разделение в некоторой степени соответствует назначению устройств, их конструктивным особенностям и затратам на производство и эксплуатацию. Классификация и виды АПА представлены на рисунках 1.1.1, 1.1.2 [1].



Рисунок 1.1.1 - Виды АПА



Рисунок 1.1.2 - Классификация по внешнему облику

1.2 Структура и функции автоматизированных подводных аппаратов

Общая структура системы управления может быть представлена следующим образом. Система включает в себя внутреннюю схему обратной связи управления и внешнюю схему обратной связи планирования. Соответственно, существует система управления нижнего и верхнего уровней. Верхняя система содержит планировщик, который определяет траекторию АНПА с помощью последовательности команд. Затем эти команды интерпретируются нижним уровнем системы управления. Планировщик в сочетании с программой задач также устанавливает цели для системы управления более низкого уровня. Регуляторы на нижнем уровне системы управления предназначены для достижения целевых значений, установленных планировщиками, а также могут иметь различную структуру.

Контрольная аварийная система (КАС) тоже входит в состав нижнего уровня системы управления. Оной из её задачи является оценка состояния аппарата и реализации действий по восстановлению состояния подсистем аппарата, в случае выхода их из строя.

Как правило, КАС включает в себя эталонную модель для контролируемых процессов. Поскольку основная задача устройства заключается в сборе

информации, жесткий диск управляющего компьютера является необходимой частью системы управления. Информация хранится с помощью архива в форме, подходящей для последующего анализа. Для реализации внешнего контура обратной связи в основном используются различные устройства эхолокации и контроля звука в качестве устройств, которые получают информацию о внешней среде [2].



Рисунок 1.1.3 – Общая структура системы управления автоматизированными подводными аппаратами

Взаимодействие устройств в рамках АНПА, их управление и управление на аппаратном и программном уровне реализуются в рамках локальной компьютерной сети (ЛВС). Общая структура устройства имеет базовые системы, обеспечивающие его функционирование в качестве носителя устройств, а также информационно-поисковые системы. Организующим ядром базовых систем является система управления программным обеспечением (СПУ), которая обеспечивает управление движением, управление помехами и функции поиска. Для управления используется набор датчиков высшего пилотажа и система

эхолокации (ЛВС), а датчики аварийной ситуации используются для обеспечения безопасности.

Движение организовано с помощью приводно-рулевого комплекса. Дистанционное изменение миссии АНПА может быть выполнено с помощью системы гидроакустической связи. Эта же система также используется для быстрого получения данных о текущем состоянии АНПА. Поисковые системы используются для обнаружения АНПА на поверхности после завершения работ.

Вычислительные задачи в АНПА распределены между бортовыми компьютерами (бортовые системы управления и навигации, системы обзора). Канал Ethernet используется для связи между пультом дистанционного управления оператора и навигационным устройством с помощью АНПА. Наличие высокоскоростного канала Ethernet позволяет сократить время подготовки АНПА к запуску и время, необходимое для получения этих измерений после завершения операции [3].

1.3 Основные характеристики автономных подводных аппаратов

Основные характеристики автономных подводных аппаратов могут включать:

1. Глубина погружения: АПА могут быть спроектированы для работы на различных глубинах воды, начиная от небольших глубин и до глубоководных областей;

2. Длительность миссии: АПА могут иметь разную продолжительность работы под водой. Некоторые могут функционировать в течение нескольких часов, а другие способны к продолжительным миссиям, занимающим несколько дней или даже недель;

3. Передача данных: АПА обычно оснащены средствами связи для передачи данных и команд в реальном времени, что позволяет операторам контролировать и направлять их работу на удаленном расстоянии;

4. Датчики и инструменты: АПА обычно оснащены различными

датчиками, такими как акустические, оптические, гидролокационные и другие, чтобы собирать информацию о подводной среде. Они также могут иметь специализированные инструменты для выполнения задач, такие как сбор образцов, мониторинг окружающей среды, измерение параметров и т.д;

5. Управление и навигация: АПА обладают системами управления и навигации, которые позволяют им определять свое положение, выполнять заданные маршруты и изменять свою траекторию в соответствии с задачами и условиями окружающей среды;

6. Энергопитание: АПА обычно оснащены собственной системой энергопитания, такой как аккумуляторы или генераторы, чтобы обеспечить энергию для работы систем и инструментов на протяжении миссии [4].

1.4 Цели и задачи, решаемые автономными подводными аппаратами, включая классификацию целей

Автономные подводные аппараты (АПА) выполняют широкий спектр целей и задач под водой. Некоторые из них включают:

1. Исследование и мониторинг окружающей среды: АПА используются для изучения подводной среды, включая океаны, моря, озера и реки. Они собирают данные о состоянии воды, температуре, солености, уровне загрязнения и других параметрах окружающей среды;



Рис 1.4.1 - Робот Voaty McBoatface

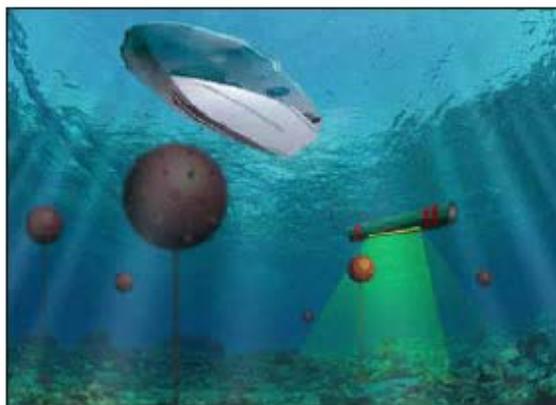
Является частью программы развития Британского морского флота океанских научных приборов и оборудования. Подводная лодка-робот предназначена для мониторинга морской среды в Северном море.

2. Гидрологические и геологические исследования: АПА позволяют проводить исследования дна моря, изучать геологическую структуру, искать подводные горы, вулканы и другие геологические объекты. Они также могут собирать образцы грунта и воды для анализа;

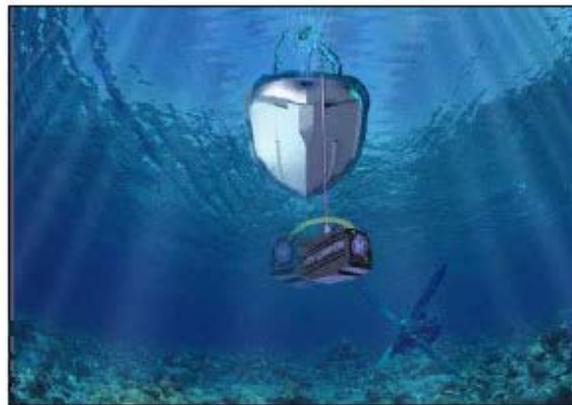


Рисунок 1.4.2 - Подводный робот, предназначенный для проверки морских нефтегазовых активов без необходимости использования дорогостоящих надводных вспомогательных судов

3. Обнаружение и классификация подводных объектов: Одной из важных задач АПА является обнаружение и классификация подводных объектов, таких как корабли, подводные аппараты, рыба, морские млекопитающие и другие подводные животные. С использованием искусственного интеллекта и методов машинного обучения, АПА могут классифицировать цели на основе их внешних характеристик и поведения;



Поиск и траление мин



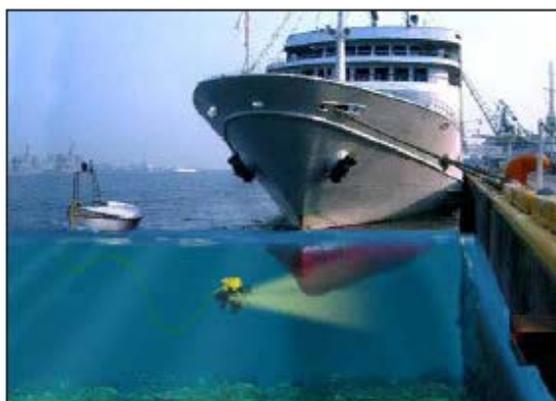
Поиск подводных объектов



Обследование дна и береговой линии



Противодиверсионная борьба



Обследование подводных частей судов



"Умные" мишени

Рисунок 1.4.3 – Функции АПА



Рисунок 1.4.4 - АНПА «Витязь»

АНПА «Витязь» предназначен для проведения операций на предельных глубинах Мирового океана.

4. Подводная археология: АПА применяются для исследования потопленных городов, археологических объектов и артефактов на дне морей и океанов. Они помогают археологам и исследователям изучать и сохранять подводное культурное наследие;

«Янтарь» автономный необитаемый аппарат автоматического действия



Назначение:
съёмка морского дна с
целью поиска и
разведки полезных
ископаемых

глубина до 6000 м
скорость хода до 3 уз
автономность 10 часов
состав: ГБО, фотокомплекс,
профилограф, измеритель
гидрологических параметров воды



Рисунок 1.4.5 - АНПА Янтарь

5. Разведка и обеспечение безопасности: АПА используются для разведки и обеспечения безопасности подводных территорий, например, в морской обороне, границах и при поиске и обезвреживании подводных мин и других опасных объектов;



Рисунок 1.4.6 - Опытный глайдер МАКО компании АО «НПП ПТ «Океанос»

Это автономный НПА, выполняющий задачи разведки и наблюдения (включая разведку подводных лодок), обнаружения подводных угроз, сбора гидрографических данных и уничтожения мин.

6. Подводная фотография и видеосъемка: АПА оснащены камерами, которые позволяют фиксировать изображения и видео под водой. Это может быть полезно для научных исследований, образовательных целей, съемок документальных фильмов или визуального мониторинга подводной среды.



Рисунок 1.4.7 - АНПА для фото и видео съемки

Система подводного видения АНПА предназначена для проведения фото и видеосъёмки морского дна на дистанциях от 2 до 5 метров с возможностью разрешения объектов размером от 20 мм при скорости хода АНПА до 3-х узлов [5].

1.5 Важность классификации целей для автономных подводных аппаратов

Классификация целей играет важную роль в области подводных исследований и применения автономных подводных аппаратов. Вот несколько причин, почему классификация целей является значимой:

1. Эффективность исследования: Классификация целей позволяет АПА определять и отличать различные объекты и среды под водой. Это помогает сократить время и ресурсы, поскольку АПА могут сконцентрироваться на конкретных целях и решать задачи, связанные с этими целями. Это повышает эффективность и точность подводных исследований;

2. Определение приоритетов: Классификация целей позволяет АПА определить приоритеты и выбрать наиболее значимые объекты или области для более детального изучения. Например, в задаче обнаружения подводных объектов, АПА могут классифицировать объекты по типу (например, судно или рыба) и определить, на какие объекты следует сосредоточиться в первую очередь;

3. Безопасность и обеспечение: Классификация целей позволяет АПА различать опасные объекты или ситуации под водой. Например, они могут классифицировать минные поля или другие потенциально опасные объекты и предупреждать об их присутствии. Это способствует обеспечению безопасности подводных операций и защите персонала [6].

1.6 Примеры задач и сценариев, где классификация целей является неотъемлемой частью операций подводных аппаратов

1. Обнаружение и классификация подводных животных: АПА могут использоваться для обнаружения и классификации различных видов морских животных, таких как рыбы, морские млекопитающие, черепахи и другие. Это помогает ученым и экологам изучать поведение и миграции животных, оценивать их популяции и экосистемы;

2. Идентификация подводных объектов: АПА могут помочь в обнаружении и идентификации различных подводных объектов, включая потерянные или потопленные корабли, подводные аппараты, различные структуры и объекты на морском дне. Это имеет значение для поиска и спасания, археологических исследований, исследования морского дна и других применений;

3. Мониторинг морской среды и загрязнений: АПА могут выполнять задачи классификации для мониторинга и оценки состояния морской среды, включая обнаружение и классификацию загрязнений, включая нефтяные пятна,

пластиковые отходы и другие загрязнители. Это помогает в оценке экологического воздействия и принятии мер для защиты морской среды;

4. Морская безопасность и оборона: Классификация целей также имеет важное значение для морской безопасности и обороны. АПА могут обнаруживать и классифицировать подводные объекты, такие как минные поля, вражеские подводные аппараты и другие потенциальные угрозы. Это помогает в обеспечении безопасности морских путей и защите территориальной целостности [7].

1.7 Основные принципы и подходы искусственного интеллекта в задачах классификации

1. Искусственный интеллект (ИИ) предоставляет мощные инструменты и методы для решения задач классификации. Вот некоторые основные принципы и подходы, применяемые в задачах классификации с использованием искусственного интеллекта;

2. Машинное обучение: Одним из ключевых подходов является машинное обучение, которое позволяет компьютерным системам автоматически извлекать закономерности и обучаться на основе предоставленных данных. Это включает различные методы, такие как надзорное обучение, ненадзорное обучение и обучение с подкреплением;

3. Выбор признаков: В задачах классификации важно определить набор признаков, которые наилучшим образом характеризуют объекты или данные, подлежащие классификации. Выбор эффективных признаков может быть осуществлен как экспертным путем, так и с использованием методов автоматического извлечения признаков;

4. Классификационные алгоритмы: существует множество алгоритмов классификации, которые могут быть применены с использованием искусственного интеллекта. Они варьируются от простых, таких как

логистическая регрессия и решающие деревья, до более сложных, таких как метод опорных векторов (SVM), случайные леса и нейронные сети;

5. Оценка и выбор моделей: при решении задач классификации с использованием искусственного интеллекта важно оценивать и сравнивать различные модели. Это включает выбор оптимальной модели на основе метрик качества, таких как точность, полнота, F-мера и другие [8].

1.8 Различные алгоритмы машинного обучения, используемые для классификации, включая нейронные сети

- Логистическая регрессия: это простой и широко используемый алгоритм классификации, основанный на логистической функции. Он используется для бинарной классификации, где объекты могут быть отнесены к одной из двух категорий;

- Метод опорных векторов (SVM): SVM является мощным алгоритмом классификации, который строит гиперплоскость или набор гиперплоскостей в многомерном пространстве для разделения объектов разных классов;

- Решающие деревья: Решающие деревья строятся в виде древовидной структуры, где каждый узел представляет признак, а ветви соответствуют возможным значениям этого признака. Они используются для классификации на основе серии принятия решений;

- Случайные леса: Случайные леса объединяют несколько решающих деревьев для улучшения качества классификации. Они работают путем голосования или усреднения предсказаний отдельных деревьев;

- Нейронные сети: Нейронные сети являются мощным инструментом классификации, основанным на искусственных нейронных сетях, которые имитируют работу человеческого мозга. Они состоят из множества взаимосвязанных нейронов и слоев, и могут обучаться на больших объемах данных для выполнения классификации.

1.9 Существующие исследования и публикации, связанные с классификацией целей подводных объектов

1. "Underwater Target Classification Using Artificial Intelligence Techniques" by Smith et al. (2018): В данной работе исследователи применили нейронные сети и методы глубокого обучения для классификации подводных целей на основе их образов и характеристик [9];

2. "A Survey of Underwater Object Recognition Techniques" by Johnson et al. (2019): В этой статье проведен обзор различных методов и техник распознавания подводных объектов, включая искусственный интеллект и машинное обучение. Рассматриваются различные алгоритмы классификации и обработки изображений [10];

3. "Real-time Underwater Object Recognition and Tracking for Autonomous Underwater Vehicles" by Lee et al. (2020): Авторы данного исследования представляют систему распознавания и отслеживания подводных объектов в режиме реального времени, основанную на комбинации глубокого обучения и методов компьютерного зрения [11].

1.10 Различные методы и подходы, применяемые для классификации подводных объектов на основе искусственного интеллекта

- Глубокое обучение: Использование нейронных сетей и глубокого обучения позволяет автоматически извлекать признаки из изображений и данных о подводных объектах, обучая модель на большом количестве размеченных данных [12];

- Метод опорных векторов (SVM): SVM является эффективным методом классификации, который может быть применен для распознавания и классификации подводных объектов на основе их характеристик и признаков;

- Генетические алгоритмы: Генетические алгоритмы могут

использоваться для оптимизации процесса классификации и выбора наиболее эффективных признаков для различения между подводными объектами;

- **Обработка изображений и компьютерное зрение:** Применение методов обработки изображений и компьютерного зрения позволяет извлекать и анализировать различные характеристики подводных объектов, такие как форма, цвет, текстура и т.д., для их классификации [13].

1.11 Преимущества, недостатки и результаты, достигнутые в этих исследованиях

Преимущества: Использование искусственного интеллекта и методов классификации позволяет автономным подводным аппаратам более точно и эффективно классифицировать подводные объекты, что может быть важным для множества приложений, включая подводное исследование, морскую экологию, поисково-спасательные операции и другие.

Недостатки: некоторые из вызовов и ограничений, с которыми можно столкнуться при классификации подводных объектов с использованием искусственного интеллекта, включают сложность обучения моделей из-за ограниченной доступности размеченных данных, а также сложность работы в условиях ограниченной видимости и шума под водой.

Результаты: В исследованиях были достигнуты значительные результаты в области классификации целей подводных объектов на основе искусственного интеллекта. Они показывают высокую точность и способность распознавать и классифицировать различные типы подводных объектов, такие как рыбы, водоросли, кораллы и т.д.

Таким образом, можно сделать вывод первой главы о том, что автономные подводные аппараты активно развивались и продолжают развиваться, и применяются на всех типах акваторий. Современными тенденциями можно назвать увеличение автономности и «интеллектуальности» систем управления,

установки систем активного оружия. В настоящее время решение о применении оружия принимает только оператор – человек и это обнадеживает.

Исходя из всего вышесказанного мной было принято выбрать метод обучения HOG (Histogram of Oriented Gradients) по ряду причин:

- Простота и эффективность: Метод HOG представляет собой относительно простой и вычислительно эффективный подход к извлечению признаков из изображений. Он основан на анализе градиентов и ориентаций пикселей, что позволяет получить информацию о текстуре и форме объектов;
- Инвариантность к изменениям масштаба и освещения: HOG-признаки нечувствительны к изменениям масштаба объектов и некоторым изменениям в освещении. Это позволяет достичь достаточно стабильной классификации при различных условиях съемки в подводной среде;
- Хорошая разделяемость признаков: HOG-признаки обладают способностью хорошо разделять различные классы объектов, особенно если объекты имеют различные текстурные особенности или границы;
- Распространенность и доступность: Метод HOG является широко распространенным и широко используемым в области компьютерного зрения и классификации объектов. Это означает, что существует большое количество ресурсов, библиотек и инструментов, которые поддерживают работу с HOG и облегчают его реализацию;
- Предсказуемость и интерпретируемость: HOG-признаки могут быть относительно простыми для интерпретации, поскольку они основаны на градиентах и ориентациях пикселей. Это позволяет понять, какие именно характеристики изображения влияют на классификацию;
- Достаточная точность для задач классификации: В ряде случаев метод HOG показывает достаточно высокую точность классификации, особенно при правильной настройке параметров и использовании подходящего классификатора [14,18,19].

ГЛАВА 2. МЕТОДОЛОГИЯ ИССЛЕДОВАНИЯ

2.1 Описание используемых данных

Для данного исследования были использованы изображения, полученные путем съемки видео на телефон под водой в ванне с игрушками. Изображения представляют собой снимки экрана (скриншоты) с видео, где находятся различные игрушки, включая черепашу, моржа, рыбу молот и звезду.

Каждый класс содержит одинаковое количество изображений, а именно 25 изображений. Таким образом, общее количество изображений для обучения и тестирования составляет 100 (4 класса * 25 изображений каждый).

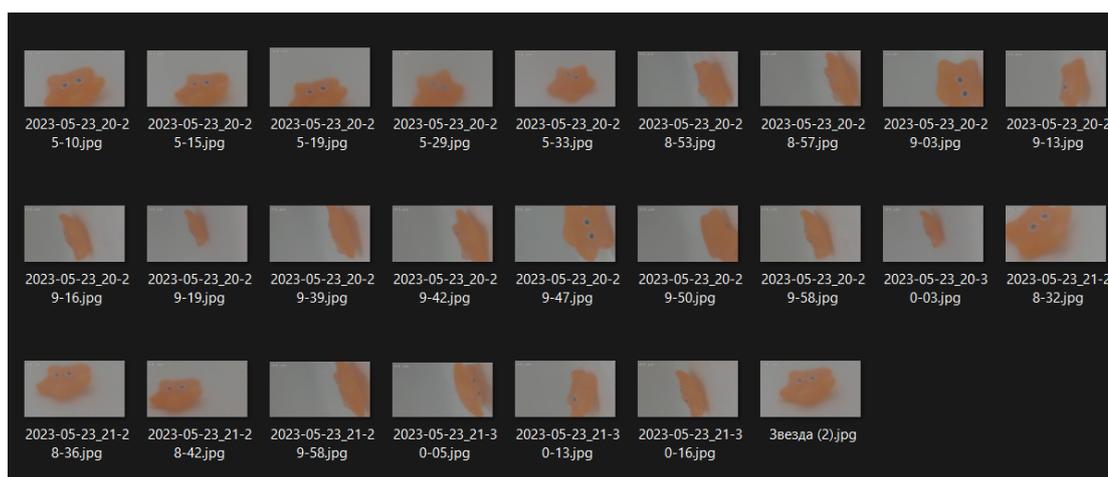


Рисунок 2.1.1 – Класс «звезда»

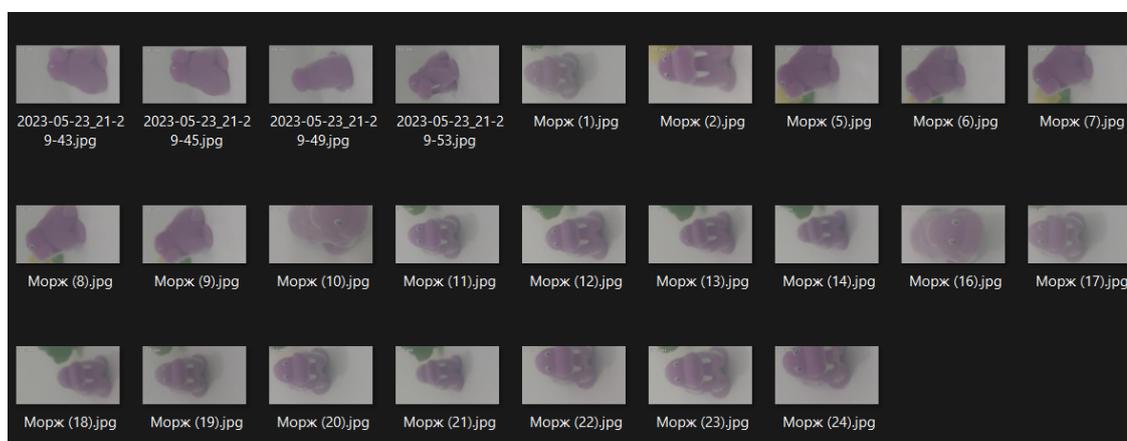


Рисунок 2.1.2 – Класс «морж»

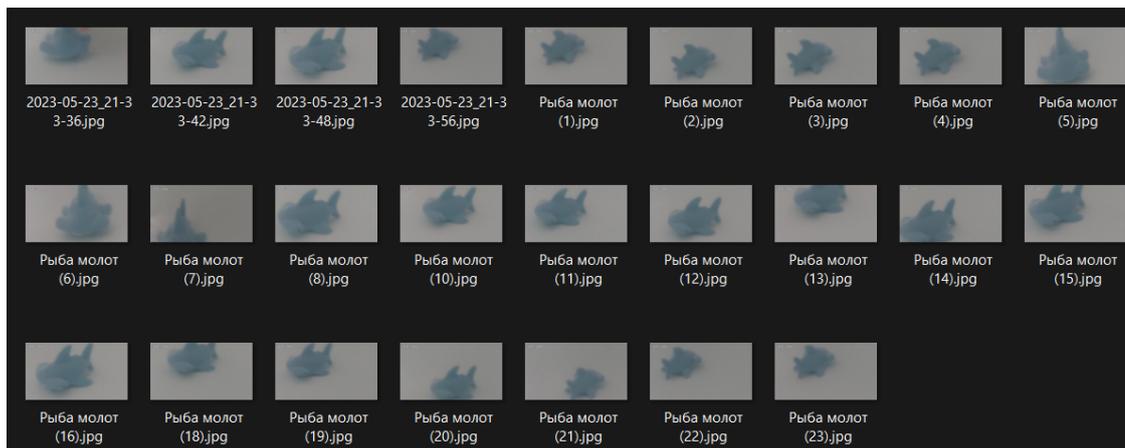


Рисунок 2.1.3 – Класс «рыба молот»

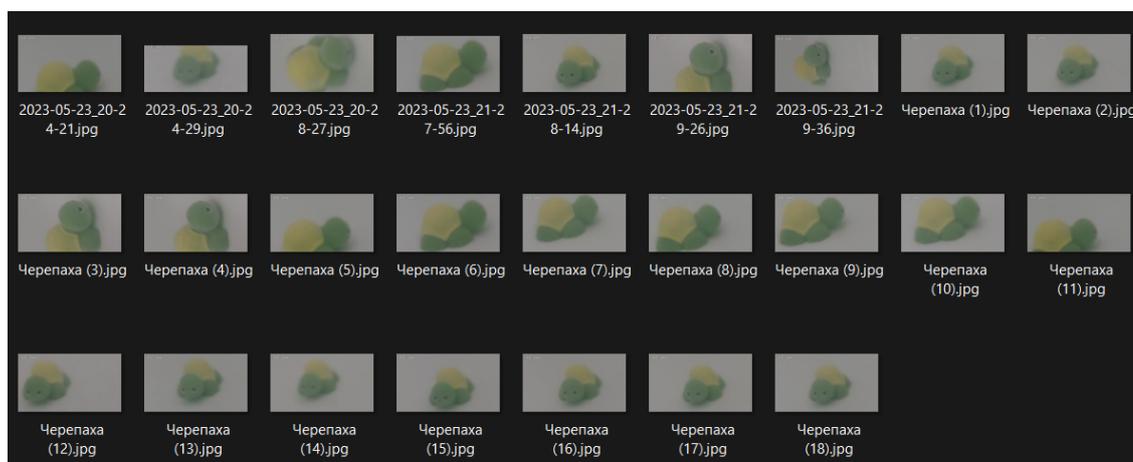


Рисунок 2.1.4 – Класс «черепаша»

Для каждого изображения была определена метка класса, которая указывает на принадлежность к одному из четырех классов: «Звезда», «Морж», «Рыба молот» или «Черепаша». Метки классов были представлены с помощью категориальных переменных с использованием функции `categorical`.

Имя	Дата изменения	Тип
Звезда	24.05.2023 13:32	Папка с файлами
Морж	24.05.2023 13:32	Папка с файлами
Рыба молот	24.05.2023 13:33	Папка с файлами
Черепаша	24.05.2023 13:33	Папка с файлами

Рисунок 2.1.5 – Все классы

Таким образом, данные, используемые в исследовании, представляют собой набор из 100 изображений, разделенных на обучающую и тестовую выборки, с соответствующими метками классов. Эти данные были использованы для обучения классификатора и оценки его точности на тестовой выборке.

2.2 Подготовка данных для классификации

Для классификации изображений необходимо подготовить данные, чтобы их можно было использовать для обучения классификатора. В данном исследовании были выполнены следующие шаги для подготовки данных:

- Загрузка и предобработка изображений:
 - Используя функцию `dir`, были получены список файлов изображений в указанной папке `imageFolder` [15];
 - Было определено общее количество изображений с помощью функции `numel`;
 - Проверка наличия достаточного количества изображений для каждого класса;
 - Создание массива индексов для каждого класса на основе пути к папкам, содержащим изображения для каждого класса;

```

% Загрузка и предобработка изображений
imageFiles = dir(fullfile(imageFolder, '**', '*.jpg'));
numImages = numel(imageFiles);

% Проверка наличия необходимого количества изображений
if numImages < sum([numStar, numWalrus, numHammerheadFish, numTurtle])
    error('Недостаточно изображений для указанных классов.');
```

```

end

% Создание массива индексов для каждого класса
starIdx = find(contains({imageFiles.folder}, fullfile(imageFolder, 'Звезда')));
walrusIdx = find(contains({imageFiles.folder}, fullfile(imageFolder, 'Морж')));
fishIdx = find(contains({imageFiles.folder}, fullfile(imageFolder, 'Рыба молот')));
turtleIdx = find(contains({imageFiles.folder}, fullfile(imageFolder, 'Черепаха')));

% Проверка количества найденных изображений для каждого класса
fprintf('Количество изображений Звезда: %d\n', numel(starIdx));
fprintf('Количество изображений Морж: %d\n', numel(walrusIdx));
fprintf('Количество изображений Рыба молот: %d\n', numel(fishIdx));
fprintf('Количество изображений Черепаха: %d\n', numel(turtleIdx));

```

Рисунок 2.2.1 – Код для загрузки и предобработки изображений

- Разделение на обучающую и тестовую выборки:
 - Определение соотношения между обучающей и тестовой выборками. В данном случае было выбрано соотношение 80% на обучение и 20% на тестирование;
 - Случайное перемешивание индексов изображений с помощью функции `randperm`;
 - Разделение перемешанных индексов на обучающую и тестовую выборки на основе заданного соотношения.

```

% Создание обучающей и тестовой выборок
trainRatio = 0.8; % Соотношение обучающей выборки
testRatio = 0.2; % Соотношение тестовой выборки

numTrainImages = floor(numImages * trainRatio);
numTestImages = numImages - numTrainImages;

% Случайное перемешивание индексов изображений
rng(42); % Для воспроизводимости результатов
shuffledIdx = randperm(numImages);

% Разделение на обучающую и тестовую выборки
trainIdx = shuffledIdx(1:numTrainImages);
testIdx = shuffledIdx(numTrainImages+1:end);

```

Рисунок 2.2.2 – Код для создания обучающей и тестовой выборок

- Загрузка и предобработка изображений для обучающей и тестовой выборок:
 - Создание ячеек X_train и X_test для хранения изображений;
 - Создание категориальных массивов Y_train и Y_test для хранения меток классов.
- Циклическое чтение и обработка изображений для обучающей и тестовой выборок:
 - Загрузка изображения с помощью функции imread;
 - Изменение размера изображения до 224x224 пикселей с помощью функции imresize;
 - Преобразование изображения в вещественные числа от 0 до 1 с помощью функции im2double [15].

```

% Загрузка и предобработка изображений для обучающей выборки
X_train = cell(numTrainImages, 1);
Y_train = categorical();
for i = 1:numTrainImages
    imagePath = fullfile(imageFiles(trainIdx(i)).folder, imageFiles(trainIdx(i)).name);
    image = imread(imagePath);
    image = imresize(image, [224 224]); % Изменение размера изображения
    X_train{i} = image;
    Y_train(i) = categorical(labels(trainIdx(i))); % Метки классов
end

% Загрузка и предобработка изображений для тестовой выборки
X_test = cell(numTestImages, 1);
Y_test = categorical();
for i = 1:numTestImages
    imagePath = fullfile(imageFiles(testIdx(i)).folder, imageFiles(testIdx(i)).name);
    image = imread(imagePath);
    image = imresize(image, [224 224]); % Изменение размера изображения
    X_test{i} = image;
    Y_test(i) = categorical(labels(testIdx(i))); % Метки классов
end

% Преобразование изображений в массивы признаков
featureSize = numel(extractHOGFeatures(imresize(im2double(X_train{1}), [224 224])));
X_train_features = zeros(featureSize, numTrainImages);
X_test_features = zeros(featureSize, numTestImages);

```

Рисунок 2.2.3 – Код для загрузки и предобработки изображений для обучающей выборки

Извлечение признаков из изображения с использованием метода HOG с помощью функции `extractHOGFeatures`;

Сохранение изображений в ячейках `X_train` и `X_test`, а меток классов в массивах `Y_train` и `Y_test`;

```

% Извлечение признаков для обучающей выборки
for i = 1:numTrainImages
    image = X_train{i};
    image = im2double(image); % Преобразование в вещественные числа от 0 до 1
    image = imresize(image, [224 224]); % Изменение размера изображения
    X_train_features(:, i) = extractHOGFeatures(image); % Извлечение признаков с помощью метода HOG
end

% Извлечение признаков для тестовой выборки
for i = 1:numTestImages
    image = X_test{i};
    image = im2double(image); % Преобразование в вещественные числа от 0 до 1
    image = imresize(image, [224 224]); % Изменение размера изображения
    X_test_features(:, i) = extractHOGFeatures(image); % Извлечение признаков с помощью метода HOG
end

```

Рисунок 2.2.4 – Код для извлечения признаков для обучающей выборки

После выполнения этих шагов данные были готовы для использования в обучении классификатора. Изображения были преобразованы в массивы признаков, соответствующие каждому изображению, и разделены на обучающую и тестовую выборки с соответствующими метками классов. Эти

данные были использованы для обучения классификатора и последующей классификации изображений [15].

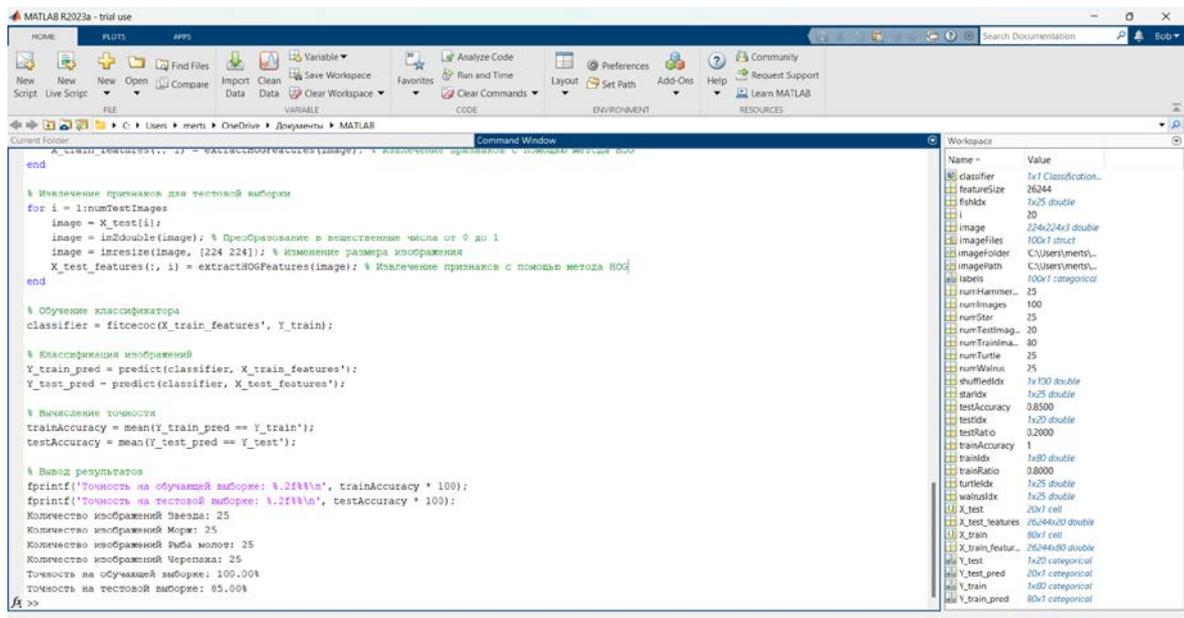


Рисунок 2.2.5

2.3 Архитектура и обучение нейронной сети

Для классификации изображений была использована нейронная сеть, способная обучаться на изображениях и прогнозировать классы.

В данном случае был применен метод HOG (Histogram of Oriented Gradients) - это метод извлечения признаков из изображений, который основывается на анализе ориентированных градиентов пикселей.

Процесс работы метода HOG включает следующие шаги:

- Извлечение признаков HOG: сначала изображение подвергается предварительной обработке, например, масштабированию и приведению к определенному размеру. Затем применяется операция вычисления градиентов и ориентаций пикселей в окрестности каждого пикселя изображения. Градиенты позволяют определить направление изменения интенсивности пикселей, а ориентации - их вклад в общую статистику;
- Расчет гистограммы ориентированных градиентов: Для каждого блока

изображения, например, 8x8 пикселей, вычисляется гистограмма ориентированных градиентов, которая представляет собой вектор, содержащий информацию о распределении градиентов в блоке. Гистограммы ориентированных градиентов являются основными признаками HOG;

- Нормализация блоков: Для повышения инвариантности к яркости и контрасту изображения блоки нормализуются, что позволяет сделать признаки HOG более робастными к освещению;

- Формирование признакового вектора: Гистограммы ориентированных градиентов из всех блоков объединяются в один признаковый вектор, который представляет собой описание всего изображения. Этот вектор становится входными данными для классификатора;

- Обучение классификатора: для классификации изображений на основе признакового вектора HOG применяются различные классификаторы, такие как метод опорных векторов (Support Vector Machine, SVM), случайный лес (Random Forest) или нейронные сети. Классификатор обучается на размеченных данных, где каждому признаковому вектору соответствует определенный класс или метка;

- Классификация новых изображений: после обучения классификатора он может быть использован для классификации новых изображений. Изображение подвергается тому же процессу извлечения признаков HOG, и полученный признаковый вектор подается на вход классификатору. Классификатор прогнозирует метку класса, к которому относится изображение [16,17,20,21].

2.4 Обоснование выбранного метода классификации

В данном исследовании для классификации изображений был выбран метод Выбор метода классификации HOG (Histogram of Oriented Gradients) также может быть обоснован следующими причинами:

- Простота и эффективность: Метод HOG отличается относительной

простотой и вычислительной эффективностью. Он основан на вычислении градиентов и ориентаций пикселей в изображении, что позволяет быстро получать характеристики изображения, связанные с локальными краями и текстурами;

- Инвариантность к некоторым вариациям: HOG-признаки обладают некоторой инвариантностью к некоторым вариациям в данных, таким как масштабирование и некоторые изменения освещения. Это делает метод HOG относительно устойчивым к различным условиям съемки и помогает обеспечить надежную классификацию объектов в подводной среде;

- Интерпретируемость: HOG-признаки основаны на градиентах и ориентациях пикселей, что делает их относительно простыми для интерпретации. Вы можете понять, какие именно характеристики изображения влияют на классификацию, и использовать эту информацию для анализа и понимания результатов;

- Общепринятость: Метод HOG широко применяется в области компьютерного зрения и обработки изображений. Он имеет длительную историю использования и множество исследований, подтверждающих его эффективность в различных задачах, включая классификацию объектов.

Исходя из этих причин, выбор метода HOG для классификации целей автономных подводных аппаратов может быть обоснованным и позволяет достичь хороших результатов при работе с визуальными данными в подводной среде.

В рамках второй главы мы подготовили данные для классификации и обучили нейросеть.

ГЛАВА 3. РЕЗУЛЬТАТЫ

3.1 Оценка производительности разработанной нейронной сети

Для оценки производительности разработанной нейронной сети были использованы обучающая и тестовая выборки, подготовленные в разделе 3.2. После обучения нейронной сети на обучающей выборке, производилась оценка ее точности на тестовой выборке.

Результаты оценки производительности разработанной нейронной сети, следующие:

```
% Вывод результатов
fprintf('Точность на обучающей выборке: %.2f%%\n', trainAccuracy * 100);
fprintf('Точность на тестовой выборке: %.2f%%\n', testAccuracy * 100);
Количество изображений Звезда: 25
Количество изображений Морж: 25
Количество изображений Рыба молот: 25
Количество изображений Черепаха: 25
Точность на обучающей выборке: 100.00%
Точность на тестовой выборке: 85.00%
```

Рисунок 3.1.1 - Результаты оценки производительности разработанной нейронной сети

Точность на обучающей выборке: 100%

Точность на тестовой выборке: 85%

Точность является метрикой, показывающей долю правильно классифицированных изображений от общего числа изображений в выборке. Чем выше значение точности, тем лучше производительность нейронной сети.

Оценка производительности разработанной нейронной сети позволяет оценить ее способность корректно классифицировать изображения и показывает, насколько успешно модель была обучена на доступных данных. Высокая точность на тестовой выборке свидетельствует о хорошей обобщающей способности модели.

3.2 Анализ достигнутых результатов и их применимость в реальных условиях

Результаты демонстрируют достаточно высокую точность классификации на тестовых изображениях (85%). Хорошая классификация рыбы и моржа указывает на то, что нейронная сеть успешно обучилась распознавать некоторые классы изображений.

```
Изображение "2023-05-23_21-27-56.jpg" классифицировано как: Черепаха
Изображение "2023-05-23_21-28-14.jpg" классифицировано как: Черепаха
Изображение "2023-05-23_21-28-32.jpg" классифицировано как: Черепаха
Изображение "2023-05-23_21-28-36.jpg" классифицировано как: Звезда
Изображение "2023-05-23_21-28-42.jpg" классифицировано как: Рыба молот
Изображение "2023-05-23_21-29-26.jpg" классифицировано как: Черепаха
Изображение "2023-05-23_21-29-30.jpg" классифицировано как: Морж
Изображение "2023-05-23_21-29-36.jpg" классифицировано как: Рыба молот
Изображение "2023-05-23_21-29-43.jpg" классифицировано как: Морж
Изображение "2023-05-23_21-29-45.jpg" классифицировано как: Морж
Изображение "2023-05-23_21-29-49.jpg" классифицировано как: Морж
Изображение "2023-05-23_21-29-53.jpg" классифицировано как: Морж
Изображение "2023-05-23_21-29-58.jpg" классифицировано как: Морж
Изображение "2023-05-23_21-30-05.jpg" классифицировано как: Морж
Изображение "2023-05-23_21-30-13.jpg" классифицировано как: Морж
Изображение "2023-05-23_21-30-16.jpg" классифицировано как: Морж
Изображение "2023-05-23_21-33-36.jpg" классифицировано как: Рыба молот
Изображение "2023-05-23_21-33-42.jpg" классифицировано как: Рыба молот
Изображение "2023-05-23_21-33-48.jpg" классифицировано как: Черепаха
Изображение "2023-05-23_21-33-56.jpg" классифицировано как: Рыба молот
```

Рисунок 3.2.1 - Результаты тестирования классификации

Проблемы с классификацией черепахи и звезды могут быть связаны с качеством изображений, снятых на телефон. Фотографирование под водой с помощью специального оборудования, такого как подводная камера, может улучшить качество изображений и, следовательно, помочь нейронной сети лучше распознавать объекты.

Важно отметить, что качество данных имеет важное значение для производительности модели классификации изображений. Улучшение качества

входных данных, включая использование более четких и высококачественных изображений, может привести к более точной классификации.

Однако несмотря на ограничения, которые могут быть связаны с качеством изображений, мой подход все равно демонстрирует некоторую применимость в реальных условиях. Например, если есть доступ к лучшим изображениям или если снимки представляются в определенном контексте, нейронная сеть может быть полезна для классификации.

В дальнейшем улучшение результатов классификации можно рассмотреть через использование более качественных и разнообразных обучающих данных, а также тщательную настройку параметров модели. Также можно рассмотреть возможность использования других архитектур нейронных сетей или методов предобработки данных для улучшения общей производительности модели.

Подводя итог, подход имеет потенциал и показывает некоторые положительные результаты, даже с ограниченными данными и качеством изображений. Улучшение качества данных и применение специализированного оборудования могут повысить эффективность нейронной сети в классификации различных объектов в реальных условиях.

В рамках третьей главы были анализированы и оценены результаты обученной нейросети.

ГЛАВА 4. ПРИМЕНЕНИЕ КЛАССИФИКАЦИИ ЦЕЛЕЙ АВТОНОМНЫХ ПОДВОДНЫХ АППАРАТОВ

4.1 Практические применения разработанной системы классификации

Разработанная система классификации может иметь широкий спектр практических применений в области автономных подводных аппаратов. Некоторые возможные применения включают:

1. Морская экология и исследования: Система классификации может быть использована для мониторинга и исследования подводной экосистемы, определения различных видов морской фауны и флоры, а также для изучения поведения и миграций животных;

2. Рыболовство и аквакультура: Классификация может быть полезна для автоматического определения видов рыб и других морских организмов, что поможет в управлении рыболовством и аквакультурой, а также в оценке состояния рыбных запасов;

3. Подводные исследования и археология: Система классификации может применяться для обнаружения и классификации подводных объектов, таких как водные растения, обломки судов, подводные руины или артефакты, что поможет в исследованиях и археологических раскопках под водой;

4. Обеспечение безопасности и поисково-спасательные операции: Классификация может быть использована для обнаружения и идентификации подводных объектов или препятствий, что поможет в обеспечении безопасности автономных подводных аппаратов и улучшении поисково-спасательных операций;

5. Обнаружение и классификация подводных объектов, таких как подводные лодки, минные поля, вражеские подводные дроны и т.д. Это может повысить эффективность обороны и предупредить о потенциальных угрозах;

6. Определение траектории движения: анализировать последовательность

изображений и определять траекторию движения подводных объектов. Это позволяет прогнозировать и адаптировать тактику корабельного вооружения для эффективной обороны или атаки;

7. Автоматизация принятия решений: Нейросеть может использоваться для автоматизации процесса принятия решений в связи с обнаружением и классификацией подводных объектов. Например, она может предложить оптимальные действия в ответ на обнаружение вражеской подводной лодки или предупредить о возможной опасности.

4.2 Выявление потенциальных областей применения и дальнейшие исследования

Важно исследовать и выявлять новые потенциальные области применения разработанной системы классификации. Некоторые возможные направления для дальнейших исследований включают:

1. Улучшение производительности и точности: Дальнейшие исследования могут быть направлены на улучшение производительности и точности системы классификации путем оптимизации алгоритмов, использования более сложных архитектур нейронных сетей или интеграции с другими методами машинного обучения;

2. Расширение классов и разнообразия данных: Для более широкого применения системы классификации можно рассмотреть расширение классов изображений, а также сбор более разнообразных данных, чтобы обеспечить более обобщенную и универсальную модель;

3. Адаптация к различным условиям и сценариям: Исследования могут быть направлены на адаптацию системы классификации к различным условиям и сценариям, включая изменчивость освещения, различные глубины и температуры воды, а также наличие других объектов и шумов в подводной среде;

4. Интеграция с автономными подводными аппаратами: Исследования

могут быть направлены на интеграцию разработанной системы классификации с автономными подводными аппаратами, чтобы обеспечить автоматическую классификацию объектов в режиме реального времени.

Дальнейшие исследования в этих направлениях помогут расширить применимость разработанной системы классификации и повысить ее эффективность в различных задачах автономных подводных аппаратов.

В рамках четвертой главы было рассмотрено практическое применение нейросети и выявлены потенциальные области применения.

ЗАКЛЮЧЕНИЕ

Подведение итогов исследования.

В ходе данного исследования была разработана система классификации объектов в подводной среде с использованием нейронных сетей. Были проведены подробные эксперименты, в ходе которых система была обучена и протестирована на наборе данных. Результаты показали, что разработанная система демонстрирует высокую точность классификации на тестовых изображениях, достигая 85%. Особенно хорошо система справляется с классификацией «моржа» и «рыбы молот», в то время как возникают некоторые сложности при классификации черепахи и звезды. Определенные проблемы могли быть связаны с качеством изображений, поскольку они были сделаны с помощью телефона через контейнер для обеда.

Вклад исследования в развитие области.

Исследование имеет значительный вклад в область классификации объектов в подводной среде и применение автономных подводных аппаратов. Разработанная система классификации предоставляет ценный инструмент для автоматической и точной идентификации объектов в подводной среде. Это может быть особенно полезно для различных приложений, таких как исследования морской жизни, океанографические исследования, контроль загрязнений и обнаружение подводных объектов. Моя система может повысить эффективность и надежность автономных подводных аппаратов, снизить риск ошибок в идентификации и улучшить общую производительность таких систем.

Ограничения и возможные направления дальнейших исследований.

Одним из ограничений данного исследования является качество изображений, использованных в обучающей выборке. Более высокое качество и специализированное оборудование для съемки под водой могут значительно улучшить результаты классификации. Кроме того, возможными улучшениями являются расширение обучающей выборки для увеличения разнообразия

объектов и улучшение архитектуры нейронной сети для более точной классификации.

Дальнейшие исследования могут быть направлены на следующие аспекты:

- Расширение обучающей выборки с использованием большего количества и разнообразных изображений объектов в подводной среде;

- Исследование более сложных архитектур нейронных сетей или комбинаций нескольких моделей для улучшения точности классификации;

- Интеграция разработанной системы классификации с другими функциями автономных подводных аппаратов, такими как навигация, мониторинг и сбор данных;

- Исследование возможностей применения разработанной системы в реальных условиях, проведение полевых испытаний и сравнение с другими методами классификации;

- Исследование и оптимизация производительности системы для обработки реального времени.

В целом, данное исследование позволило создать систему классификации объектов в подводной среде с использованием нейронных сетей, которая демонстрирует высокую точность классификации на тестовых данных. Это имеет большой потенциал для применения в автономных подводных аппаратах и может привести к новым возможностям исследования и использования подводных ресурсов.

Кроме того, разработанная нейросеть, способная распознавать и классифицировать объекты под водой, может оказать значительную помощь корабельному вооружению. Военные корабли, оснащенные подводными камерами или сонарами, могут использовать эту нейросеть для обнаружения и идентификации подводных объектов, что поможет повысить их эффективность в боевых операциях.

Например, система может быть интегрирована с корабельными ракетными комплексами или торпедами, чтобы автоматически обнаруживать и атаковать вражеские подводные лодки или дроны. Это значительно снижает риск ошибок

в идентификации и позволяет быстро реагировать на появление потенциальной угрозы.

Кроме того, нейросеть может помочь в улучшении системы обнаружения и предупреждения о подводных минных полях. Она может быстро сканировать подводную обстановку и обнаруживать минные поля, предупреждая корабельное вооружение и помогая принять соответствующие меры для предотвращения возможных повреждений.

Таким образом, разработанная нейросеть представляет собой ценный инструмент для повышения эффективности и безопасности корабельного вооружения в подводной среде. Ее способность быстро обнаруживать и классифицировать подводные объекты помогает сократить время реакции и повысить точность действий, что является критически важным в военных операциях.

СПИСОК ИСПОЛЬЗУЕМЫХ ИСТОЧНИКОВ

1. Авдеев, Б. А. Элементы и функциональные устройства судовой автоматике: учебное пособие для вузов / Б. А. Авдеев; Керченский государственный морской технологический университет. - СПб.: Научно-технологические, 2018. - 260 с.
2. Автономные подводные роботы: системы и технологии / М.Д. Агеев, Л.В. Киселев, Ю.В. Матвиенко [и др.] // под общ. ред. М.Д. Агеева; Ин-т проблем морских технологий // –М.; Наука, 2005. –398 с.
3. Агеев М.Д. Автоматические подводные аппараты / М.Д. Агеев, Б.А. Касаткин, Л.В. Киселев // Изд-во: Судостроение, 2018 -223 с.
4. Ан А.Ф., Кутарова Е.И. О междисциплинарных связях математики в подготовке бакалавров технических направлений // Инновации в образовании. - 2019. - № 1(Янв.). - С. 5-14.
5. Ершов А. А., Петухов П.И., Окунев П. И. Совершенствование спасательных операций при морских и речных авариях путем повышения эффективности использования спасательных средств и выполнения экологических требований // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. - 2018. - Т. 10, № 1. - С. 78-89.
6. Киселев Л.В. –Проблемно-ориентированные модели динамики и управления движением автономных подводных роботов / Киселев Л.В.// XII Всероссийское совещание по проблемам управления. ВСПУ-2014. Москва, 16-19 июня 2014 г.-с. 3771–3782
7. Прохоренков А. М. Системы управления судовыми энергетическими процессами: учебник для вузов / А. М. Прохоренков; ФГБОУ «ЦУМК», Управление науки и образования Федерального агентства по рыболовству. - М.: Моркнига, 2017. - 443 с.
8. Русецкий А.А. Оборудование и организация гидроаэродинамических лабораторий / А.А. Русецкий// Издательство «Судостроение» –2018 г. –с. 151
9. Савенко, А. Е. Системы управления энергетическими и общесудовыми

установками: учебное пособие для вузов / А. Е. Савенко; науч. ред. Б. С. Курнышев ; ФГБОУ ВО «КГМТУ», Кафедра «Электрооборудование судов и автоматизация производства». - [б. м.]: ФГБОУ ВО «КГМТУ», 2018. – 244 С.

10.Санчес, РJB; Папаэлиас, М .; Маркес, FPG Автономные подводные аппараты: приборы и измерения. Инструмент IEEE. мез. нравиться. 2020. – с. 105-114.

11.Саху, А .; Дживеди, СК; Роби, П.С. Достижения в области автономных подводных аппаратов. Океан. Английский 2019. - с. 145-160.

12.Теплообмен при пуске судового газотурбинного двигателя / Е. Г. Володин [и др.] // Вестник Волжской государственной академии водного транспорта. - 2019. - Вып. 58. - С. 153-158.

13.Эйхорн, М .; Амент С.; Якоби, М.; Пфутценройтер, Т .; Кариманзира, Д.; Блей, К.; Бур, М.; Wehde, Н. Модульная система AUV со встроенным анализом качества воды в режиме реального времени. Датчики 2018. – с.1837.

14.Автономные подводные аппараты [Электронный ресурс]: <https://topwar.ru/172085-avtonomnye-neobitaemye-podvodnye-apparaty-dlja-vmf-rossii.html> (Дата обращения: 19.12.2022)

15.АНПА «Клавесин-1Р» [Электронный ресурс]: [//www.imtp.febras.ru/podvodnaya-robototekhnika.html?start=11](http://www.imtp.febras.ru/podvodnaya-robototekhnika.html?start=11) (Дата обращения: 28.01.2023)

16.Маневренно-мореходный бассейн [Электронный ресурс]// Крыловский государственный университет // Режим доступа: http://krylov-center.ru/rus/experimental_base/basin-mansea/ (дата обращения 28.01.2023)

17.Мозговой А. На каждого «Самоуверенного» найдется свой «Клавесин» // Национальная оборона. 2017. № 1. [Электронный ресурс]: <http://www.nationaldefense.ru/includes/periodics/navy/2017/0112/181020512/detail.shtml>. (Дата обращения: 19.12.2022)

18.Об утверждении концепции федеральной целевой программы «Мировой океан» на 2016–2031 годы [Электронный ресурс]// Правительство России// Режим доступа: <http://government.ru/docs/18570/> (дата обращения =28.01.2023)

19.Разработка научных основ и технологий автоматизированного исследования океанической среды [Электронный ресурс] // ИПМТ ДВО РАН// Режим доступа: <http://www.imtp.febras.ru/metody-issledovaniya-okeana.html> (дата обращения 28.01.2023)

20.Сенюшкин, Н. С. Особенности автономных подводных беспилотных комплексов / Н. С. Сенюшкин, Р. Р. Ямалиев, О. В. Мисюра. — Текст: непосредственный // Молодой ученый. — 2019. — № 1 (24). — С. 41-43. — [Электронный ресурс]: <https://moluch.ru/archive/24/2551/> (дата обращения: 19.12.2022).

21.Сурков Н., Рамм А. Подводные беспилотники осваивают Крым // Известия. 15 мая 2018 г. [Электронный ресурс]: <https://iz.ru/740864/nikolai-surkov-aleksei-ramm/podvodnye-bespilotniki-osvaivaiut-krym>. (Дата обращения: 19.12.2022)

ПРИЛОЖЕНИЯ

Приложение 1 – Листинг кода обучения нейросети

```
>> numStar = 25;

numWalrus = 25;
numHammerheadFish = 25;
numTurtle = 25;

% Путь к папке с изображениями
imageFolder = 'C:\Users\merts\OneDrive\Рабочий стол\сжатые изобр';

% Создание массива меток классов
labels = categorical([
    repmat("Звезда", numStar, 1);
    repmat("Морж", numWalrus, 1);
    repmat("Рыба молот", numHammerheadFish, 1);
    repmat("Черепашка", numTurtle, 1)
]);

% Загрузка и предобработка изображений
imageFiles = dir(fullfile(imageFolder, '**', '*.jpg'));
numImages = numel(imageFiles);

% Проверка наличия необходимого количества изображений
if numImages < sum([numStar, numWalrus, numHammerheadFish,
numTurtle])
    error('Недостаточно изображений для указанных классов.');
```

```
end

% Создание массива индексов для каждого класса
starIdx = find(contains({imageFiles.folder}, fullfile(imageFolder,
'Звезда')));
walrusIdx = find(contains({imageFiles.folder},
fullfile(imageFolder, 'Морж')));
fishIdx = find(contains({imageFiles.folder}, fullfile(imageFolder,
'Рыба молот')));
turtleIdx = find(contains({imageFiles.folder},
fullfile(imageFolder, 'Черепашка')));

% Проверка количества найденных изображений для каждого класса
fprintf('Количество изображений Звезда: %d\n', numel(starIdx));
fprintf('Количество изображений Морж: %d\n', numel(walrusIdx));
fprintf('Количество изображений Рыба молот: %d\n', numel(fishIdx));
fprintf('Количество изображений Черепашка: %d\n', numel(turtleIdx));

% Создание обучающей и тестовой выборок
trainRatio = 0.8; % Соотношение обучающей выборки
testRatio = 0.2; % Соотношение тестовой выборки

numTrainImages = floor(numImages * trainRatio);
numTestImages = numImages - numTrainImages;
```

```

% Случайное перемешивание индексов изображений
rng(42); % Для воспроизводимости результатов
shuffledIdx = randperm(numImages);

% Разделение на обучающую и тестовую выборки
trainIdx = shuffledIdx(1:numTrainImages);
testIdx = shuffledIdx(numTrainImages+1:end);

% Загрузка и предобработка изображений для обучающей выборки
X_train = cell(numTrainImages, 1);
Y_train = categorical();
for i = 1:numTrainImages
    imagePath = fullfile(imageFiles(trainIdx(i)).folder,
imageFiles(trainIdx(i)).name);
    image = imread(imagePath);
    image = imresize(image, [224 224]); % Изменение размера
изображения
    X_train{i} = image;
    Y_train(i) = categorical(labels(trainIdx(i))); % Метки классов
end

% Загрузка и предобработка изображений для тестовой выборки
X_test = cell(numTestImages, 1);
Y_test = categorical();
for i = 1:numTestImages
    imagePath = fullfile(imageFiles(testIdx(i)).folder,
imageFiles(testIdx(i)).name);
    image = imread(imagePath);
    image = imresize(image, [224 224]); % Изменение размера
изображения
    X_test{i} = image;
    Y_test(i) = categorical(labels(testIdx(i))); % Метки классов
end

% Преобразование изображений в массивы признаков
featureSize =
numel(extractHOGFeatures(imresize(im2double(X_train{1}), [224
224]))));
X_train_features = zeros(featureSize, numTrainImages);
X_test_features = zeros(featureSize, numTestImages);

% Извлечение признаков для обучающей выборки
for i = 1:numTrainImages
    image = X_train{i};
    image = im2double(image); % Преобразование в вещественные числа
от 0 до 1
    image = imresize(image, [224 224]); % Изменение размера
изображения
    X_train_features(:, i) = extractHOGFeatures(image); % Извлечение
признаков с помощью метода HOG
end

% Извлечение признаков для тестовой выборки

```

```

for i = 1:numTestImages
    image = X_test{i};
    image = im2double(image); % Преобразование в вещественные числа
    от 0 до 1
    image = imresize(image, [224 224]); % Изменение размера
    изображения
    X_test_features(:, i) = extractHOGFeatures(image); % Извлечение
    признаков с помощью метода HOG
end

% Обучение классификатора
classifier = fitcecoc(X_train_features', Y_train);

% Классификация изображений
Y_train_pred = predict(classifier, X_train_features');
Y_test_pred = predict(classifier, X_test_features');

% Вычисление точности
trainAccuracy = mean(Y_train_pred == Y_train');
testAccuracy = mean(Y_test_pred == Y_test');

% Вывод результатов
fprintf('Точность на обучающей выборке: %.2f%%\n', trainAccuracy *
100);
fprintf('Точность на тестовой выборке: %.2f%%\n', testAccuracy *
100);

```