

Астафьев А.В.

*Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264 г. Муром, Владимирской обл., ул. Орловская, д. 23
Alexandr.Astafiev@mail.ru*

Двухэтапная архитектура распознавания активности по Wi-Fi радиосигналам на основе CSI

Распознавание человеческой активности по радиосигналам является перспективным направлением бесконтактного мониторинга, востребованным в задачах умного дома, медицины, промышленной безопасности и Интернета вещей. В отличие от видеосистем, решения на основе Wi-Fi сигналов не зависят от освещения и не нарушают приватность, однако обладают высокой чувствительностью к шумам и изменениям среды, что снижает точность классификации.

В работе предлагается двухэтапная архитектура распознавания активности, основанная на анализе канальных матриц Wi-Fi (CSI). На первом этапе выполняется предварительное детектирование наличия движения, позволяющее отфильтровать периоды покоя и исключить их из дальнейшей обработки. На втором этапе производится классификация типа активности с использованием сверточной нейронной сети.

Первый этап нацелен на предварительное детектирование наличия движения и состоит из следующих этапов:

1. Извлечение амплитуд. Для каждой канальной матрицы вычисляется матрица амплитуд размерности $M \times N \times S$ путём поэлементного вычисления модуля комплексных значений CSI.
2. Фильтрация шумов. Для каждой временной последовательности амплитуд применяется упрощённый фильтр Калмана для подавления высокочастотных шумов.
3. Снижение размерности. К отфильтрованным данным применяется метод главных компонент (PCA). Для дальнейшей обработки сохраняются первые две главные компоненты, характеризующие низкочастотные и динамические изменения сигнала.
4. Сегментация сигнала. Временной ряд разбивается на перекрывающиеся сегменты фиксированной длины.
5. Вычисление статистических признаков. Для каждого сегмента вычисляются среднее значение и стандартное отклонение.
6. Пороговая классификация сегментов. Сегмент классифицируется как содержащий движение, если хотя бы один из статистических параметров превышает соответствующий порог, определённый по калибровочному набору данных.

Результатом этапа является последовательность временных интервалов, содержащих движение.

Второй этап реализует распознавание типа активности и состоит из следующей последовательности шагов:

1. Формирование временных тензоров. Для интервалов, содержащих движение, формируются тензоры амплитуд размерности $(MN) \times S \times T$, описывающие динамику сигнала во времени.
2. Нейросетевая классификация. Полученные тензоры подаются на вход сверточной нейронной сети, формирующей на выходе вектор вероятностей классов активности.
3. Принятие решения. Класс активности определяется по максимальному значению выходного вектора вероятностей.

Экспериментальные исследования проводились в лабораторном помещении для трёх типов активности: движения всего тела, верхней и нижней части тела. Показано, что ошибка детектирования движения не превышает 1%, а итоговая точность классификации активности достигает 97,3%. Дополнительно продемонстрирована устойчивость алгоритма при переносе в схожее помещение.

Полученные результаты подтверждают, что использование предварительного детектирования движения позволяет существенно повысить надёжность и точность систем распознавания активности по Wi-Fi радиосигналам.

Белякова А.С., Сенечкин Д.О.

*Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264 г. Муром, Владимирской обл., ул. Орловская, д. 23
asbelyakova@rambler.ru*

Исследование применения нейросетевых моделей для автоматического определения объема круглого леса на фотографиях

Древесина является одним из ключевых природных ресурсов, широко используемых в строительстве, производстве мебели и энергетике. Особое значение имеет круглый лес – это спиленные стволы деревьев, очищенные от веток. Транспортировка осуществляется автомобилями с открытым кузовом, а контроль объема груза играет важную роль для расчетов стоимости, соблюдения норм загрузки и безопасности. Традиционный ручной замер объема трудоемок и подвержен ошибкам. Развитие технологий компьютерного зрения позволяет автоматизировать этот процесс с использованием обычных фотографий, сделанных в полевых условиях. Целью данной работы является изучение возможностей нейросетевых моделей для распознавания круглого леса на изображениях, обучение модели на датасете и анализ полученных результатов.

Анализ каждого изображения включает несколько последовательных шагов. Исходные фотографии содержат автомобиль с грузом круглого леса и специальный эталонный объект для определения масштаба. Первый этап – обнаружение этого эталона и расчет масштаба изображения. Второй этап – детектирование торцов бревен с помощью нейронной сети. Третий этап – оценка объема древесины. Это можно сделать двумя способами: приблизительно, по габаритам загруженной площадки автомобиля, или более точно, рассчитав объем каждого бревна по его диаметру. При этом такие параметры, как длина бревен и коэффициент полндревесности, вводятся в систему вручную.



а) Исходное изображение

б) Результат детектирования

Рис. 1 – Бревна на лесовозе

Для обучения нейронной сети необходим размеченный набор данных. Разметка выполнялась с использованием инструмента Computer Vision Annotation Tool (CVAT), который предоставляет удобный интерфейс для аннотирования объектов на изображениях. Всего было размечено 45 изображений. Для итогового тестирования было дополнительно взяты 10 изображения без разметки.

Для задачи детектирования была выбрана архитектура YOLO (You Only Look Once). Ее ключевые преимущества – высокая скорость работы (один проход через сеть) и способность показывать удовлетворительные результаты даже при малом объеме обучающих данных. Были

рассмотрены и другие методы, но они оказались менее подходящими. Например, Наг-каскады хорошо работают для детектирования лиц, но плохо справляются со сложными объектами вроде бревен. Методы, основанные на Local Binary Patterns (LBP) или Histogram of Oriented Gradients (HOG), уступают современным нейросетям в точности. Простые нейросетевые архитектуры, такие как MLP или SimpleNet, не предназначены для непосредственной локализации объектов на изображении и требуют дополнительных шагов предобработки.

Обучение модели проводилось с использованием фреймворка Ultralytics API. Была выбрана сегментационная модель YOLOv8n-seg как достаточно легкая и эффективная для работы с небольшим датасетом. После обучения модель была протестирована на четырех изображениях, которые не участвовали в обучении. Визуальный анализ результатов показал, что модель успешно обнаруживает часть бревен на каждом тестовом снимке, что подтверждает ее работоспособность. Однако детекция не является полной: некоторые объекты остаются не распознанными.

Полученные результаты позволяют сделать несколько важных выводов:

1. Модель продемонстрировала способность находить торцы бревен даже в сложных условиях, хотя и не со стопроцентной точностью.
2. При этом разметка для обнаруженных объектов оказывается геометрически точной, что позволяет достоверно оценивать их диаметры.
3. Было отмечено одно ложное срабатывание на постороннем объекте (водяном знаке), что указывает на необходимость дополнительной настройки. Ключевой вывод заключается в том, что даже при малом размере обучающей выборки модель показала принципиальную пригодность для решения задачи.
4. Основными путями для значительного улучшения точности являются увеличение объема и качества датасета, а также тонкая настройка параметров обучения и детекции.

Результаты исследования подтверждают высокий потенциал нейросетевых технологий для автоматизации трудоемкого процесса оценки объема древесины.

Литература

1. Ultralytics. YOLOv8 Documentation [Электронный ресурс]. – Режим доступа: <https://docs.ultralytics.com/> (дата обращения: 04.10.2025). – Описание архитектуры, API и методов обучения моделей YOLOv8.
2. Gonzalez, R. C., Woods, R. E. Digital Image Processing. – 4th ed. – Pearson, 2018. – 1168 p.
3. Goodfellow, I., Bengio, Y., Courville, A. Deep Learning. – MIT Press, 2016. – 800 p.
4. Лесохозяйственный регламент. Методы измерения и учета круглых лесоматериалов. – М.: ФГУП «Стандартинформ», 2020.

Борданов И.А., Щаников С.А.

*Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирской обл., ул. Орловская, 23
bordanov2011@yandex.ru*

Разработка алгоритмов оценки функциональной корректности искусственных нейронных сетей на базе мемристоров

На сегодняшний день мемристоры считаются одними из самых перспективных электронных компонентов для аппаратной реализации искусственных нейронных сетей (ИНС) [1]. В таких ИНС мемристоры в основном используются в качестве синапсов нейронов, храня весовые коэффициенты в виде сопротивлений. Одним из основных преимуществ применения мемристоров в ИНС является возможность энергонезависимого хранения весов синапсов. Другим важным преимуществом является то, что объединение мемристоров в кроссбар-массивы позволяет выполнять операцию матричного умножения за один такт [2]. Это позволяет ИНС на базе мемристоров (ИНСМ) демонстрировать на порядок более лучшие показатели по производительности на площадь чипа и на ват потребляемой энергии по сравнению с классической полностью цифровой реализацией ИНС на архитектуре Джона фон Неймана [3].

С другой стороны, мемристоры имеют один основной недостаток, который связан с невозможностью задания требуемого значения сопротивления, соответствующего выбранному весовому коэффициенту, с идеальной точностью, в связи с нелинейностью и асимметрией изменения сопротивления, вариациями сопротивления от цикла к циклу и др. [4] Это соответственно может привести к ухудшению функциональной корректности ИНСМ. Поэтому возникает необходимость оценки функциональной корректности ИНСМ на этапе проектирования [5].

Для решения описанной проблемы в работе предложено несколько алгоритмов, применение которых позволяет выполнить оценку функциональной корректности ИНСМ независимо от её метрики. Разработанные алгоритмы используются для оценки функциональной корректности ИНСМ с помощью компьютерного моделирования с применением эмпирических моделей мемристоров.

Разработанные алгоритмы были апробированы на примере оценки функциональной корректности для сверточной нейронной сети обученной решению задачи классификации изображений элементов гардероба.

Литература

1. Xu J. et al. A Cascaded ReRAM-based Crossbar Architecture for Transformer Neural Network Acceleration // ACM Transactions on Design Automation of Electronic Systems. 2024. DOI: 10.1145/3701034.
2. Yao P. et al. Fully hardware-implemented memristor convolutional neural network // Nature. – 2020. Т. 577. С. 641–646. DOI: 10.1038/s41586-020-1942-4.
3. Михайлов А.Н. и др. На пути к реализации высокопроизводительных вычислений в памяти на основе мемристорной электронной компонентной базы // Физмат. 2023. Т. 1, № 1. С. 42-64. DOI: 10.56304/S2949609823010021.
4. Amirsoleimani A. et al. In-Memory Vector-Matrix Multiplication in Monolithic Complementary Metal–Oxide–Semiconductor-Memristor Integrated Circuits: Design Choices, Challenges, and Perspectives // Advanced Intelligent Systems. 2020. Т. 2, № 10. С. 2000115. DOI: 10.1002/aisy.202000115.
5. Bordanov I., Antonov A., Korolev L. Simulation of calculation errors in memristive crossbars for artificial neural networks // 2023 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM). IEEE, 2023. С. 1008-1012.

*Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264 г. Муром, Владимирской обл., ул. Орловская, д. 23
bulaevav.work@yandex.ru*

Экспериментальная апробация применимости методов топологического анализа изображений для задач обнаружения и идентификации объектов на снимках с беспилотных летательных аппаратов

Применение БПЛА в современной хозяйственной деятельности человека находит все большее распространение. Задачи, для решения которых ранее требовалось применения большой и малой авиации, в современных условиях могут решаться с применением беспилотных летательных аппаратов, например, мониторинг лесных и сельскохозяйственных угодий, обнаружения объектов.

В МИ ВлГУ на протяжении уже многих лет ведутся исследования в области применения алгоритмов топологического анализа изображения для решения широкого круга задач.

Одно из направлений – обнаружение объектов на изображениях на основе набора изображений-прототипов[1].

Суть предложенного алгоритма заключается в том что:

- 1) формируется набор изображений-прототипов объектов интереса $OИ = \{OИ_1, OИ_2, \dots, OИ_N\}$;
- 2) анализ изображения и выделение областей-интереса, в которых могут размещаться искомые объекты интереса $ОблИ = \{ОблИ_1, ОблИ_2, \dots, ОблИ_M\}$;
- 3) для каждого изображения-прототипа строится его баркод $БК_{OИ} = \{БК_{OИ1}, БК_{OИ2}, \dots, БК_{OИN}\}$;
- 4) для каждой области интереса так же строится баркод $БК_{ОблИ} = \{БК_{ОблИ1}, БК_{ОблИ2}, \dots, БК_{ОблИM}\}$;
- 5) далее происходит попарное сравнение баркодов из множеств $БК_{OИ}$ и $БК_{ОблИ}$, и вычисление их коэффициента подобия КП;
- 6) если КП не меньше заданного порога, то считается, что в области интереса находится искомый объект.

Использование баркодов позволяет сократить количество объектов-прототипов в датасете в сравнении с их требуемым числом для обучающей выборки при применении нейросетевого подхода.

Алгоритм топологического анализа изображений в качестве входных параметров использует величины минимального и максимального размеров окна интереса и значение коэффициента подобия.

В настоящий момент уже доказана применимость подхода использования баркодов к решению практических задач по оценке подобия объектов, по их сопоставлению на разномасштабных картах [2], по обнаружению объектов [3].

Цель данного исследования состоит в рассмотрении применимости алгоритма топологического анализа к изображениям других сцен.

В дополнение к уже указанным ранее параметрам алгоритма топологического анализа (минимальная, максимальная окна области интереса, коэффициент подобия баркодов) было принято решение рассмотреть влияние параметров самих изображений: яркости, контрастности, резкости. Вариация графических параметров применялась по-отдельности к обрабатываемым изображениям и изображениям объектов-прототипов.

$$P = \frac{\text{верно найденные объекты}}{\text{кол} - \text{во объектов категории на изображении}} * \frac{\text{верно найденные объекты}}{\text{кол} - \text{во всех обнаружений категории}} \quad (1)$$

Оценка результатов велась с использованием формулы точности и полноты (1).

Представленные далее результаты относятся к экспериментам по обнаружению объектов «Автомобиль» на изображениях «Городской среды».

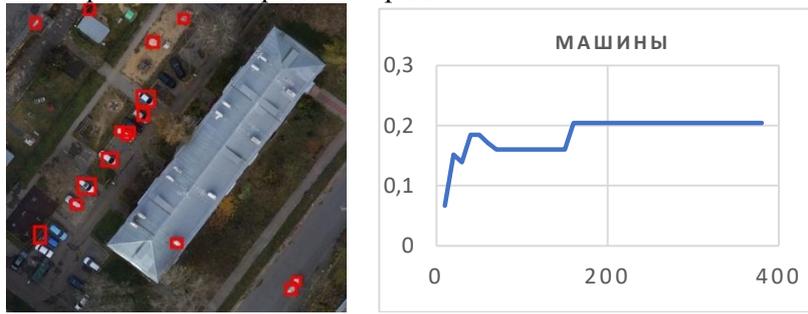


Рис.1. Оценка результатов обнаружения в зависимости от числа объектов-прототипов

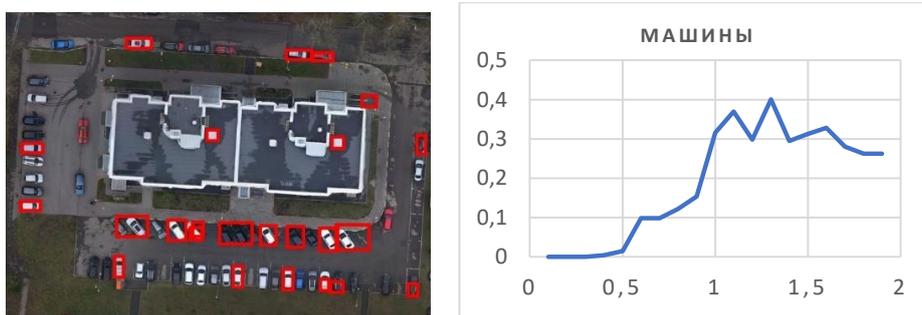


Рис.2. Оценка результатов обнаружения в зависимости от коэффициента яркости изображений-прототипов

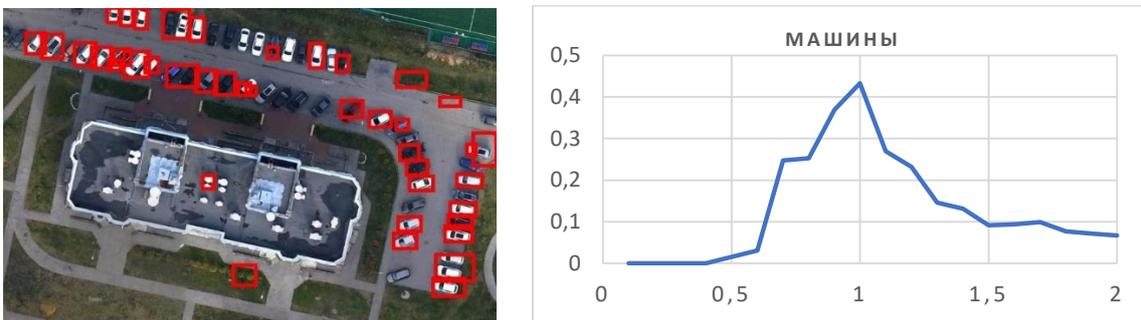


Рис.3. Оценка результатов обнаружения в зависимости от коэффициента яркости обрабатываемых изображений



Рис.4. Оценка результатов обнаружения в зависимости от минимального размера окна области интереса

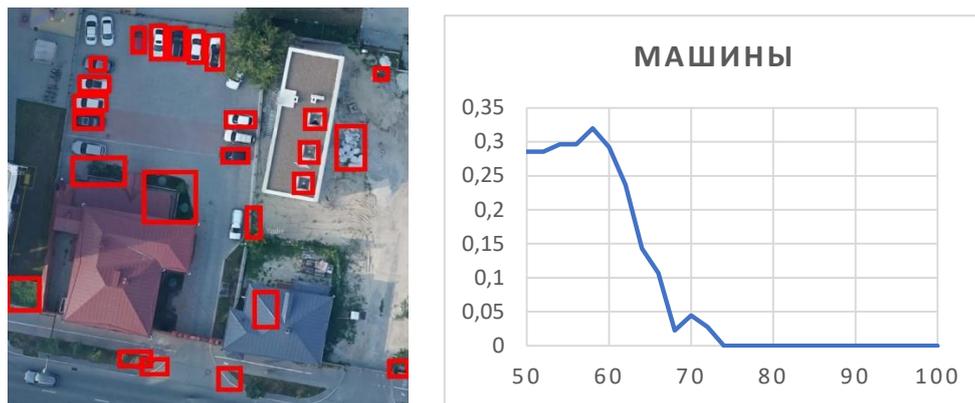


Рис.5. Оценка результатов обнаружения в зависимости от коэффициента подобия

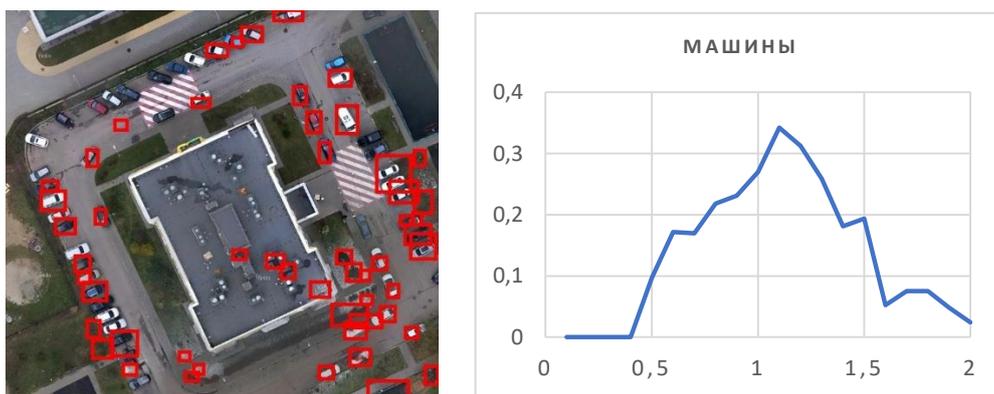


Рис.6. Оценка результатов обнаружения в зависимости от контрастности обрабатываемых изображений

Экспериментальные исследования показывают, что системной зависимости результатов обнаружения объектов от какого-либо одного параметра не прослеживается.

Изменение графических характеристик изображений объектов-прототипов или обрабатываемых изображений приводит к ухудшению результатов.

Коэффициент подобия при его приближении к единице уменьшает количество распознанных объектов, при уменьшении же его значения растет число ложных обнаружений, что так же снижает общий результат распознавания.

Исследованием было подтверждено отсутствие зависимости результатов алгоритма топологического анализа от графических характеристик изображений объектов-прототипов и обрабатываемых изображений.

Литература

1. Модели и алгоритмы обработки и анализа данных в геоинформационных системах / К.В. Купцов, С.В. Еремеев, Д.Е. Андрианов. – М. : ВНИИГеосистем, 2020. – 98 с. : ил.
2. Еремеев, С.В. Алгоритм совмещения пространственных объектов разномасштабных карт на основе топологического анализа данных / С.В. Еремеев, Д.Е. Андрианов, В.С. Титов // Компьютерная оптика. – 2019. – Т. 43, № 6. – С. 1021-1029. – DOI: 10.18287/2412-6179-2019-43-6-1021-1029.
3. Еремеев С.В. Обнаружение многолетних бугров пучения с использованием декомпозиции цифровых моделей рельефа по топологическим признакам / С.В. Еремеев, А.В. Абакумов, Д.Е. Андрианов, И.В. Богоявленский, Р.А. Никонов // Современные проблемы дистанционного зондирования Земли из космоса. - 2023. - Т. 20. № 6. - С. 129–143.

Догадина Е.П., Серебряков Н.С.

*Федеральное государственное образовательное бюджетное учреждение высшего образования «Финансовый университет при Правительстве Российской Федерации»
107023, Москва, 4-й Вешняковский пр-д, 4
epdogadina@fa.ru*

Цифровизация и автоматизация торговых операций в розничной сети

Современная розничная торговля переживает глубокую трансформацию. На смену интуитивному управлению приходят данные, алгоритмы и автоматизированные системы. Цифровизация и автоматизация торговых операций становятся ключевыми составляющими для повышения уровня конкурентоспособности.

В розничной сети бизнес-процессы торговых операций охватывают все этапы взаимодействия с товаром – от его поступления до продажи конечному покупателю, а также сопутствующие управленческие и сервисные функции. В работе рассматриваются ключевые бизнес-процессы, связанные с продажей и работой с клиентами: обслуживание покупателей в торговом зале (офлайн) или в приложении (онлайн); консультирование, демонстрация товаров, помощь в выборе; оформление покупок через POS-системы или онлайн-корзину; обработку возвратов и обменов; работу с жалобами. Организация данных процессов требует подробного анализа и структурирования действий. Данных целей можно достичь благодаря использованию различных нотаций, позволяющих подробно описать бизнес-логику процессов.

Для описания процессов будем использовать несколько типов нотаций: IDEF0 (Integration DEFinition for Function Modeling), DFD (Data Flow Diagram), UML (Unified Modeling Language), BPMN ((Business Process Model and Notation). Данные нотации имеют сильно различные форматы и составление может значительно различаться, однако они выполняют одну и ту же функцию: структурируют и помогают легче понять логику приложения. Нотация IDEF0 – это методология моделирования бизнес-процессов, которая используется для описания функций, выполняемых системой, и взаимосвязей между этими функциями. В работе рассматривалось два уровня модели: контекстная и декомпозиция. Нотация UML – это стандартный язык для описания, визуализации, проектирования и документации элементов информационных систем. UML предоставляет множество графических элементов и нотаций, позволяющих создавать разнообразные виды диаграмм, отражающих разные аспекты системы. За счет комбинации различных диаграмм можно достичь целостного взгляда на модель проектируемой системы, что крайне полезно при разработке. Нотация DFD – это графическая модель, используемая для представления потоков информации в системе, а также для описания процессов обработки, хранения и передачи данных. DFD широко применяется в анализе и проектировании информационных систем, особенно на этапе сбора требований и функционального моделирования бизнес-процессов. BPMN отлично подходит для моделирования последовательности действий, участников и потоков данных. BPMN чётко показывает хронологический порядок, она может идентифицировать всех участников процесса и распределять задачи, а также BPMN позволяет отслеживать движение информации.

Благодаря нотации BPMN в работе показаны основные этапы автоматизации продаж в розничной сети за счет наглядного представления диаграмм «AS IS» и «TO BE». BPMN-диаграмма бизнес-процесса продажи товара «TO BE» включает в себя автоматизацию на основе чат-ботов на базе искусственного интеллекта, позволяющую снять нагрузку с сотрудников отдела продаж, ускорить процесс продаж, а также снизить количество ошибок

Литература

1. Дюма, А. Управление бизнес-процессами: BPMN, IDEF, DFD / А. Дюма, М. Росс. – Пер. с англ. – М.: ДМК Пресс, 2020. – 432 с.
2. Кузнецов, В. П. Проектирование информационных систем в торговле / В. П. Кузнецов, Е. А. Соколова. – СПб.: Питер, 2021. – 288 с.
3. Aiogram 3.x: современный фреймворк для Telegram Bot API на Python. Официальная документация. URL: <https://docs.aiogram.dev/> (дата обращения: 20.12.2025).

Догадина Е.П., Сметанина К.С.
*Федеральное государственное образовательное бюджетное учреждение высшего образования «Финансовый университет при Правительстве Российской Федерации»
107023, Москва, 4-й Вешняковский пр-д, 4
epdogadina@fa.ru*

Роль искусственного интеллекта в современной розничной торговле

Искусственный интеллект (ИИ) стал ключевым звеном трансформации розничной торговли, обеспечивая не просто автоматизацию рутинных операций, но и качественно новый уровень принятия решений на основе данных. В отличие от традиционных алгоритмов, ориентированных на выполнение заранее заданных правил, ИИ способен обучаться, адаптироваться к изменяющимся условиям и выявлять скрытые закономерности в поведении потребителей. Это делает его незаменимым инструментом для оптимизации всех этапов процесса продажи товаров – от прогнозирования спроса до завершения транзакции и постпродажного обслуживания. Современные ритейлеры всё чаще интегрируют ИИ-решения в свои операционные и маркетинговые процессы, стремясь повысить эффективность, снизить издержки и усилить лояльность клиентов. Особенно актуально это в условиях высокой конкуренции, роста электронной коммерции и ужесточения требований к персонализации.

Рассмотрим основные направления применения ИИ в автоматизации продаж. К ним относятся: прогнозирование спроса и управление ассортиментом; персонализация клиентского опыта; динамическое ценообразование; автоматизация взаимодействия с клиентом; предиктивная аналитика и проактивное управление продажами. Благодаря возможностям машинного обучения, обработки естественного языка (NLP), компьютерного зрения и анализа больших данных, ИИ трансформирует традиционные подходы к продажам, делая их более точными, персонализированными и эффективными.

В работе рассматривается интеграция искусственного интеллекта в уже существующие корпоративные информационные системы, которые формируют основу операционной деятельности компаний. В российской и странах СНГ бизнес-среде доминирующей платформой такого рода выступает «1С: Предприятие». Это универсальная система, используемая тысячами розничных сетей для учёта, управления запасами, продаж, финансов и персонала. Однако стандартные функциональные возможности «1С» зачастую недостаточны для реализации передовых ИИ-решений, таких как машинное обучение, анализ поведения клиентов или предиктивная аналитика. Это стимулирует развитие гибридных архитектур, в которых «1С: Предприятие» (конфигурация «1С: Управление торговлей») выступает в роли центрального хранилища операционных данных (информация о товарах, клиентах, заказах, остатках, ценах, продажах, возвратах и т.д.), а внешние ИИ-модули – в роли «интеллектуального надстройки», обеспечивающего более высокий уровень автоматизации и принятия решений.

Интеграция «1С:Управление торговлей» с внешними системами искусственного интеллекта открывает для розничных компаний путь к умной автоматизации. В таком случае рутинные операции не просто ускоряются, но и оптимизируются на основе данных. Такой синтез надёжной учётной платформы и передовых аналитических возможностей ИИ позволяет повысить эффективность управления торговыми операциями, усилить клиентский опыт и обеспечить конкурентное преимущество в условиях цифровой экономики. При этом успех интеграции зависит не столько от технологий, сколько от чёткого понимания бизнес-задач, качества данных и грамотной архитектуры взаимодействия между системами.

Литература

4. Генеративный искусственный интеллект в розничной торговле: повышение коммерческой эффективности и снижение рисков / Д. А. Устинов, Д. О. Емельянцеv, И. В. Дуров, А. С. Татаренков // *Инновации и инвестиции*. – 2024. – № 7. – С. 211-215. – EDN OXGEGH.

5. Жубанов, А. Е. Искусственный интеллект в розничной торговле и электронной коммерции: улучшение пользовательского опыта через персонализацию, предсказательную аналитику и взаимодействие в реальном времени / А. Е. Жубанов, Н. Ю. Ульянин // Парадигма. – 2025. – № 5-6. – С. 73-79. – EDN CHZCRX.

Крекина С.А.

*Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264 г. Муром, Владимирской обл., ул. Орловская, д. 23
skrekina@bk.ru*

Системы на базе LLM для выявления ошибок школьников в математических выражениях с автоматической генерацией персонализированных упражнений

Сфера применения искусственного интеллекта (ИИ) неуклонно расширяется, охватывая производство, медицину, экономику, образование и креативные индустрии. Благодаря экспоненциальному росту данных, прогрессу вычислительных мощностей и эволюции архитектур моделей ИИ существенно трансформирует образовательные процессы, включая адаптивное обучение, рекомендательные системы, оценку знаний и создание учебных материалов.

Данный материал фокусируется на роли ИИ в процессах оценивания и демонстрирует, как передовые технологии решают ключевые вызовы этой области. Главное преимущество ИИ-обратной связи — способность обеспечивать одновременно всесторонний анализ (за счет обработки больших объемов данных) и глубокое понимание динамики обучения и успехов студентов. Чат-боты на базе ИИ, имитирующие устную или письменную коммуникацию, открывают широкие возможности для персонализации через диалоговое взаимодействие.

Современные образовательные платформы требуют инструментов для автоматизированного выявления ошибок студентов, особенно повторяющихся, например, в работе с математическими выражениями, что тормозит освоение фундаментальных навыков. Крупные языковые модели (LLM), такие как GPT, демонстрируют высокий потенциал в решении математических задач и генерации контента, но нуждаются в доработке под педагогические цели. Системы, интегрирующие LLM с механизмами верификации логики, не только обнаруживают ошибки, но и создают индивидуализированные задания, соответствующие трендам персонализированного обучения, где ИИ выступает в роли тьютора [1].

Исследование Liang, показало эффективность адаптации LLM для предоставления полезной обратной связи на курсах программирования: модели генерируют ценные рекомендации для студентов и помогают преподавателям предсказывать риски неуспеваемости. [2].

Еще один аналогичный пример — кейс университета Мадрида (UAM), где разработана система персонализированной обратной связи для учебных курсов. Разрабатывая модель, авторы пробовали несколько видов промптов для разных GenAI: ChatGPT демонстрировал более высокую производительность по сравнению с Bard и Llama. Получившийся инструмент называется GePeTo («Generative AI-based Personalized Guidance Tool») и интегрирует сразу несколько систем[3]:

- 1) использует анонимизированные данные множества учащихся курса и анализирует их;
- 2) подключается к серверу генеративного ИИ (авторы использовали несколько разных моделей и далее называют их просто GenAI) и создает персонализированные рекомендации для учащегося, адаптируя их к определенному количеству символов и формату интерактивной модели в реальном времени;
- 3) проверяет ответы GenAI перед их отображением на дашбордах учащихся.

ИИ облегчает персонализацию обратной связи, выгодную как студентам (индивидуальные подсказки), так и преподавателям (диагностика проблем и прогнозирование рисков). Особо перспективно применение в инклюзивном образовании, где ИИ-обратная связь по объективности, детализации и оперативности не уступает человеческой, а порой и превосходит ее.

Литература

1. Новые подходы к оцениванию: искусственный интеллект как драйвер изменений в образовании / Е. Ю. Карданова (научная редакция), С. В. Тарасов, А. Е. Иванова, Э. М. Юсупова, Д. А. Грачева, К. В. Тарасова, И. С. Денисов, Д. П. Талов, А. С. Струкова ; Национальный исследовательский университет «Высшая школа экономики», Институт образования. — М.: НИУ ВШЭ, 2025. — 88 с. — 100 экз. — (Современная аналитика образования. № 5 (88)).

2. Liang, Weixin, Zhang, Yuhui «Can large language models provide useful feedback on research papers? A large-scale empirical analysis»

3. A. Becerra, Z. Mohseni, J. Sanz and R. Cobos, "A Generative AI-Based Personalized Guidance Tool for Enhancing the Feedback to MOOC Learners," 2024 IEEE Global Engineering Education Conference (EDUCON), Kos Island, Greece, 2024, pp. 1-8, doi: 10.1109/EDUCON60312.2024.10578809.

Кульков Я.Ю., Емельянов В.А.

*Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264 г. Муром, Владимирской обл., ул. Орловская, д. 23
u_mail@mail.ru*

Повышение качества детекции и сегментации наноструктур на основе модернизированных YOLO-моделей

Исследование наноструктур, таких как наночастицы золота и углеродные цепочки, является важным направлением современных материаловедческих и физико-химических исследований. Электронная микроскопия позволяет получать изображения с высоким пространственным разрешением, однако их интерпретация требует значительных временных затрат, что обуславливает необходимость автоматизации процессов распознавания и классификации объектов на микроскопических изображениях [1-2].

В работе представлено исследование, направленное на модернизацию и оптимизацию нейронных сетей для автоматизированного анализа изображений углеродных наноструктур, полученных методом электронной микроскопии [3-4]. Рассмотрены две задачи: детекция наночастиц золота и сегментация карбиновых цепочек. Для задачи сегментации выполнен подбор эффективных методов аугментации данных с целью повышения устойчивости модели к геометрическим особенностям объектов. Экспериментальные результаты продемонстрировали улучшение качества распознавания как визуально, так и по метрикам точности, полноты и F1-меры, особенно в случаях сложных и нестабильно обнаруживаемых структур.

Для повышения обобщающей способности моделей были протестированы различные методы аугментации, учитывающие специфику исходного набора изображений. Аугментации применялись как средствами библиотеки *ultralytics*, так и с использованием библиотеки *PIL* на этапе предварительной обработки обучающей выборки. Анализ показал, что геометрические преобразования (повороты, смещения, масштабирование и отражения) оказывают положительное влияние, компенсируя вариативность форм и ориентаций объектов. В то же время гауссово размытие приводило к ухудшению результатов из-за сглаживания искомым структур, а цветовые преобразования не оказали заметного эффекта при обучении, но могут быть полезны на этапе предобработки входных данных.

Переход на архитектуру *YOLO11n* для задачи детекции оказался успешным: удалось не только сохранить уровень качества, но и увеличить число распознанных объектов без роста вычислительных затрат. В задаче сегментации была выполнена замена *YOLOv8n-seg* на более производительную *YOLO11m-seg* с одновременным внедрением аугментаций, что привело к значительному росту качества предсказаний.

Полученные результаты подтверждают эффективность проведённой модернизации нейронных сетей. В качестве направлений дальнейших исследований рассматриваются расширение обучающего набора, использование дополнительных методов аугментации, настройка гиперпараметров и автоматизация этапа предобработки изображений, включающего адаптивную коррекцию яркости, контраста и резкости, что может дополнительно повысить устойчивость и точность моделей.

Литература

1. Yan He, Huakai Xu, Gang Ouyang, Guowei Yang. Thermal properties of carbyne nanostructures, *Results in Physics*, Volume 34, 2022, 105311, ISSN 2211-3797.
2. Guowei Yang. Synthesis, properties, and applications of carbyne nanocrystals. *Materials Science and Engineering: R: Reports*, Volume 151, 2022, 100692, ISSN 0927-796X.
3. A. L. Zhiznyakov, Y. Y. Kulkov, and V. A. Emelyanov, "Development of an algorithm for recognizing nanoparticles in electron microscope images", 2023 *Dynamics of Systems, Mechanisms and Machines (Dynamics) (IEEE)*, 2023, pp. 1–3, doi: 10.1109/Dynamics 60586.2023.10349602.

4. A. L. Zhiznyakov, Y. Y. Kulkov and V. A. Emelyanov, “Recognition Algorithm of Carbon Chains in Nanoparticle Assemblies from Electron Microscopy Images”, 2025 International Russian Smart Industry Conference (SmartIndustryCon), Sochi, Russian Federation, 2025, pp. 849-854, doi: 10.1109/SmartIndustryCon65166.2025.10986003.

Курочкин И.И., Дадашев Р.Р.
ИППИ РАН
127051, г. Москва, Большой Каретный переулок, д.19, стр.1
kurochkin@itp.ru

Адаптация методов балансировки нагрузки для гетерогенной распределенной вычислительной системы

Для решения актуальных прикладных задач с большим количеством данных часто используются глубокие нейронные сети [1]. К таким задачам относятся задачи анализа и обработки изображений [2]. Большой объем данных не позволяет обучать глубокие нейронные сети на одном вычислительном узле. Подходы, основанные на увеличении ресурсов одного вычислительного узла, быстро достигают своих пределов из-за ограничений аппаратного обеспечения и экспоненциального роста стоимости. Другой подход, предполагает совместное использование множества вычислительных узлов для распределения вычислений [3]. Идея подхода заключается в использовании множества вычислительных устройств, объединенных с помощью телекоммуникационной сети для решения задач глубокого обучения. В рамках данного подхода, можно использовать высокопроизводительные многопроцессорные вычислительные системы или распределенные вычислительные системы. Распределенные вычислительные системы обладают рядом особенностей: гетерогенность вычислительных узлов, существенные ограничения на обмен данными между узлами, возможные отключения узлов и каналов передачи данных, наличие ошибок в расчетах. Однако, при учете этих особенностей, распределенная система обладает рядом преимуществ: широкие возможности для масштабирования, отказоустойчивость, возможность подключения почти всех типов вычислительных узлов.

При этом следует заметить, что гетерогенность является одной из отличительных особенностей распределенных систем. Под гетерогенностью понимается не только различие в имеющихся ресурсах на узлах (вычислительные ресурсы, ресурсы хранения, возможности телекоммуникационной сети), но и различия в архитектуре и количестве вычислительных устройств, использование различных операционных систем, а также вероятность отказов. Как правило, различия между узлами присутствуют по нескольким типам ресурсов. Будем называть распределенную вычислительную систему, системой с высокой степенью гетерогенности, если присутствуют существенные различия (в разы) для нескольких типов ресурсов или различие (на порядок и более) для одного ресурса. К примеру, наличие на одном узле только центрального процессора (CPU), а на другом, помимо CPU, еще специализированных вычислительных устройств (GPU). Следует заметить, что сильная гетерогенность (высокая степень гетерогенности) узлов характерна для вычислительных систем с различными типами узлов (виртуальные машины, сервера с GPU, персональные вычислительные устройства и др.). Для разных типов вычислительных узлов, вероятно, будет характерно различное поведение (периоды работоспособности, вероятность ошибок и отказов).

Существует множество подходов и методов распределенного глубокого обучения [1]. С помощью некоторых методов можно достаточно эффективно реализовать распределенное обучение только на гомогенных или слабо гетерогенных вычислительных системах (к примеру, на ресурсах частного облака). Но в случае, когда распределенная вычислительная система имеет высокую степень гетерогенности необходимо не только использовать определенные методы распределенного обучения, но и адаптировать их к особенностям распределенной системы.

К основным способам адаптации можно отнести:

- Методы распределения данных между узлами;
- Методы формирования локальных датасетов;
- Настройка системы выдачи заданий (балансировки нагрузки).

Ограничения на распространение данных между узлами распределенной системы может существенно ухудшить метрики качества обучения моделей глубоких нейронных сетей. Это происходит из-за того, что частные наборы данных (частные датасеты) по отдельности

часто не сбалансированы и не являются IID (независимые одинаково распределенные случайные величины). Кроме того, узлы распределенной системы могут иметь разное количество ресурсов: вычислительная мощность, объем оперативной памяти, пропускная способность канала передачи данных, наличие видеокарты, свободное место на диске. Данные особенности делают необходимым не только наличие подсистемы балансировки нагрузки, но методов формирования локальных датасетов, а также адаптацию методов агрегации результатов.

Из-за возможных регулярных или внезапных отключений вычислительных узлов распределенной системы, а также ошибок в расчетах необходимо использование современных методов балансировки нагрузки. В последнее время получили распространение методы балансировки нагрузки, использующие методы машинного обучения [4]. Такие методы позволяют не только оценить возможность успешного расчета определенного задания на вычислительном узле, но и позволяют оценить вычислительную сложность задания. Оценка вычислительной сложности каждого задания необходима, когда разброс вычислительной сложности для множества задач высок и может достигать различий в нескольких порядков, к примеру, на комбинаторных задачах и задачах распределенного глубокого обучения.

Одной из основных особенностей решения задач распределенного глубокого обучения является наличие итеративного процесса распределенного обучения. Результатом каждой итерации распределенного обучения является агрегацией результатов локального глубокого обучения на узлах. Поэтому заданиями в рамках задач распределенного глубокого обучения будет проведение локального обучения на узлах. Будем рассматривать решение задачи классификации изображений с помощью распределенного обучения с параметрическим сервером и синхронной агрегацией результатов. Для эффективной реализации данного вида распределенного обучения необходимо, чтобы локальное обучение на разных узлах выполнялось за одинаковое время. Так как узлы распределенной системы, в общем случае, имеют различную вычислительную мощность, то за одно и то же время они могут выполнить разное количество вычислений. Регулирование сложности выполняемой задачи локального обучения может осуществляться с помощью: регулирования размера локального датасета, а также подбора количества эпох локального глубокого обучения, коэффициента скорости обучения и других гиперпараметров локальной модели. Так как распределенная вычислительная система гетерогенна, то подбор гиперпараметров необходим для каждого узла, а не только для узла усредненными характеристиками (ресурсами). Кроме того, агрегация результатов в конце одной итерации распределенного обучения может происходить не на полном множестве результатов. Такой подход позволяет сократить время ожидания в случае ошибок вычислений и недоступности некоторой доли узлов распределенной вычислительной системы. Следует учесть, что имеются ограничения по изменению гиперпараметров локальной модели, которые вызваны возможным дрейфом локальных моделей и ухудшению метрик качества распределенного обучения.

Так как ресурсы на узлах вычислительной системы могут изменяться в процессе распределенного обучения, необходимо производить мониторинг статистики расчета заданий по каждому узлу на протяжении всего процесса распределенного обучения. А также учитывать результаты мониторинга в подсистеме балансировки нагрузки.

Проведенные эксперименты по распределенному обучению на открытых датасетах, в том числе CIFAR10/CIFAR100, Lozinsky dataset [5], на современных моделях глубоких нейронных сетей позволили подтвердить необходимость модификации системы балансировки нагрузки и применения описанных методов при решении задач классификации изображений методами распределенного обучения.

Литература

1. Langer, M. et al. "Distributed Training of Deep Learning Models: A Taxonomic Perspective". // IEEE Transactions on Parallel and Distributed Systems, Vol.31(12), 2020. P. 2802–2818. DOI:10.1109/tpds.2020.3003307.
2. Kurochkin I.I., Prun A.I., Balaev A.A. Federated Deep Learning for Solving an Image Classification Problem on a Desktop Grid System // Phys. Part. Nuclei 55, 2024. pp. 430-432. DOI:10.1134/S1063779624030560.

3. Anderson D. P. BOINC: A Platform for Volunteer Computing //Journal of Grid Computing, Vol. 18, N. 1, 2020. pp. 99-122. DOI: 10.1007/s10723-019-09497-9
4. Muchori J. G., Mwangi P. M. Machine learning load balancing techniques in cloud computing: a review // International Journal of Computer Applications Technology and Research, Vol.11, Issue 06, 2022. pp. 179-186. DOI:10.7753/IJCATR1106.1002
5. Kurochkin I.I., Kostylev I.S. Solving the Problem of Texture Images Classification Using Synchronous Distributed Deep Learning on Desktop Grid Systems // Communications in Computer and Information Science, Vol.1331, Springer Cham, 2020. pp. 647-657. DOI:10.1007/978-3-030-64616-5_55

Мареев А.В.

*Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264 г. Муром, Владимирской обл., ул. Орловская, д. 23
a.v.mareev@yandex.ru*

Использование современных микрокомпьютеров со встроенным NPU в компьютерном зрении на примере Orange Pi 5 Max

Современные задачи автоматизации на производстве и в быту, решаемые, например, такими технологиями, как беспилотные летательные аппараты, беспилотный транспорт, робототехника, требуют компактных и энергоэффективных решений, способных выполнять анализ в реальном времени при помощи портативных вычислительных устройств [1-2]. Этому требованию отвечает рынок одноплатных микрокомпьютеров, оснащенных специализированными нейропроцессорами (NPU). Одним из разработчиков таких систем-на-кристалле (SoC) является компания Rockchip, чьи чипы с архитектурой ARM и интегрированными NPU обеспечивают высокую производительность для задач компьютерного зрения. На их базе такие производители, как Radxa, ASUS, Orange Pi, Banana Pi, выпускают широкий спектр устройств для периферийных вычислений, что делает данную аппаратную платформу массовой и доступной для внедрения в промышленные решения.

Среди устройств на SoC Rockchip для промышленных задач компьютерного зрения выделяются платы с чипом RK3588 (например, Orange Pi 5 Max, Radxa Rock 5B) и более бюджетным RK3566 (Radxa Zero 3W). Ключевым критерием выбора является производительность NPU. Orange Pi 5 Max на RK3588 обладает NPU с производительностью до 6 TOPS, что в несколько раз превышает возможности RK3566, при этом энергопотребление при полной загрузке не превышает 20 Вт, что является весомым критерием при построении портативных систем компьютерного зрения. Это делает его оптимальным для одновременной обработки видеопотока и работы с современными нейросетевыми моделями, такими как YOLO, где важна низкая задержка. Помимо рассмотренных устройств, можно также отметить недавно выпущенный микрокомпьютер Orange Pi 6 Plus на базе Armv9 Cix P1 CD8160, включающего в себя NPU модуль на 30 TOPS, а при объединении всех вычислительных блоков устройства (CPU+GPU+NPU) заявляется производительность до 45 TOPS. Но данное устройство потребляет 100 Вт, что может быть недостатком при построении портативных устройств.

Для работы со встроенным NPU Rockchip предоставляет формат RKNN, который позволяет максимально использовать аппаратное ускорение, обеспечивая наивысшую эффективность на выбранной платформе по сравнению с выполнением задач на CPU или использовании универсальных форматов моделей. Набор инструментов RKNN Toolkit позволяет конвертировать модели PyTorch (например, YOLO11 [3]) в проприетарный формат RKNN, полностью использующий возможности NPU Rockchip. Официальные тесты производительности от Ultralytics чипа RK3588 демонстрируют следующие результаты для различных версий YOLO11 в формате RKNN [4]:

Таблица 1 – Сравнение производительности моделей YOLO на процессоре RK3588

Модель	mAP50-95(B)	Время инференса (мс/изобр.)	Размер (МБ)
YOLO11n	0,505	71,5	7,4
YOLO11s	0,578	98,9	20,7
YOLO11m	0,629	235,3	41,9

Эти данные показывают ключевой компромисс между скоростью и точностью: компактная модель YOLO11n обеспечивает детекцию быстрее 15 кадров/сек (71.5 мс) с приемлемой точностью, что делает её кандидатом для задач реального времени. Выбор конкретной модели и её последующая дообучение на датасете объектов интереса позволят найти баланс, необходимый для работы в заданном видеопотоке.

В рамках работы предлагается следующая методология создания системы на Orange Pi 5 Max:

- 1) формирование датасета изображений целевых объектов интереса;
- 2) выбор и дообучение модели;
- 3) обученная модель экспортируется в формат RKNN с указанием целевой платформы `rk3588` для аппаратной оптимизации. Процесс выполняется на ПК;
- 4) оптимизированная модель `*.rknn` загружается на Orange Pi 5 Max, где разворачивается программный конвейер для захвата видеопотока, выполнения инференса на NPU и постобработки результатов;
- 5) система тестируется по метрикам скорости, точности распознавания и энергоэффективности, сравнивается с режимом работы только на CPU платформы.

Таким образом, современная аппаратная платформа на базе SoC Rockchip, в частности микрокомпьютер Orange Pi 5 Max с чипом RK3588, предлагает энергоэффективное и высокопроизводительное решение для задач компьютерного зрения в реальном времени, которое, в связке с оптимизированным под NPU форматом моделей RKNN и методикой выбора и дообучения нейросетевых моделей (например, семейства YOLO), формирует готовую методологию для создания портативных и промышленных систем автоматизированного анализа видеопотока.

Литература

1. Nguyen H. X. et al. Multi-Task Learning for Age, Gender, and Emotion Recognition on Edge Processing //Smart Systems and Devices. – 2025. – Т. 35. – №. 3. – С. 009-015.
2. CRĂCIUN R. A., Pietraru R. N., MOISESCU M. A. Internet of things platform benchmark: An artificial intelligence assessment //REVUE ROUMAINE DES SCIENCES TECHNIQUES—SÉRIE ÉLECTROTECHNIQUE ET ÉNERGÉTIQUE. – 2024. – Т. 69. – №. 1. – С. 97-102.
3. YOLO Documentation. Модели, поддерживаемые Ultralytics. URL: <https://docs.ultralytics.com/ru/models/>. Дата обращения: 2026.
4. YOLO Documentation. Экспорт Rockchip RKNN для моделей Ultralytics YOLO26. URL: <https://docs.ultralytics.com/ru/integrations/rockchip-rknn/#real-world-applications> Дата обращения: 2026.

Новиков А.О., Ватулин Э.И.
Юго-Западный государственный университет
305040, г. Курск, ул. 50 лет Октября, 94
alexnov4616@gmail.com

Специализированное итерационное устройство для возведения бинарной матрицы в квадрат

Умножение матриц является фундаментальной операцией, лежащей в основе решения широкого класса вычислительных задач. К их числу относятся методы решения дифференциальных уравнений, алгоритмы машинного обучения и искусственного интеллекта, обработка и анализ изображений, а также задачи теории графов и распознавания образов.

Особую актуальность данная операция приобретает в контексте проектирования систем логического управления (СЛУ), где ключевую роль играют бинарные (булевы) матрицы, представляющие собой способ задания бинарных отношений. Ряд операций с ними сводится к нахождению транзитивного замыкания, что может быть реализовано путем серии операций возведения бинарной матрицы в степень [1].

Несмотря на использование простейших логических операций «И» и «ИЛИ», задача умножения бинарных матриц сопряжена со значительной вычислительной сложностью при выполнении умножения матриц большого размера, что требует как высокой эффективности по времени, так и по аппаратным ресурсам.

Ключевой проблемой, ограничивающей производительность, является низкая эффективность типовых программных реализаций на центральных процессорах (CPU) при использовании классического алгоритма умножения матриц. Помимо высокой временной сложности самой операции, проблема заключается в нерегулярном доступе к данным, который приводит к неоптимальному использованию кэш-памяти CPU.

Существуют различные пути решения поставленной задачи: применение векторных SIMD-расширений CPU, обработка матриц на графических ускорителях (GPGPU), программируемых логических схемах (ПЛИС), внедрения специализированных устройств (ASIC), схемотехнически реализующих операцию умножения.

Важно отметить, что временные затраты на умножение бинарных матриц возможно существенно сократить с помощью досрочного прерывания логической операции «ИЛИ», что в общем случае невозможно при умножении целочисленных или вещественных матриц.

Специализированные устройства для умножения матриц подразделяются на две большие группы: систолические и итерационные. Систолические устройства особенно эффективны, но обладают высокой аппаратной сложностью. Итерационные более просты по своей архитектуре, при этом необходимые затраты времени обычно выше [2, 3].

В рамках выполненного научного исследования поставлена задача разработка итерационного устройства с оптимизированной структурой, позволяющей сократить время операции, и реализующего базовый алгоритм умножения матриц с возможностью досрочного прерывания процесса умножения с выдачей признака готовности.

Основу предложенного устройства составляют три сдвиговых регистра, блок коэффициентов матрицы, логические элементы и триггер. Блок коэффициентов состоит из $n \times n$ блоков хранения (где n – размер матрицы), предназначенных для хранения значений ячеек матрицы, возводимой в квадрат, и выдачи с помощью трехпортовой схемы в соответствии с адресацией коэффициентов для проведения операций и выгрузки результатов умножения во внешнее устройство. Сдвиговые регистры используются для адресации в блоке коэффициентов матрицы обрабатываемой строки i , столбца j , переменной k . Логические элементы управляют процессом загрузки коэффициентов и этапами умножения. Триггер применяется для хранения промежуточного результата умножения.

В качестве прототипа выступает устройство, представленное в патенте [4]. Недостатком указанного устройства являются большие временные затраты на выполнение операции возведения матрицы в квадрат. Предлагаемое устройство предназначено для их уменьшения путем сокращения длины логических цепочек, отвечающих за загрузку, чтение данных и

отвечающих за процесс умножения. Значительное сокращение временных затрат достигается путем введения в блок коэффициентов матрицы пирамидальной схемы из двухвходовых элементов «ИЛИ» для выдачи данных, что снижает задержку с линейной до логарифмической зависимости от размера обрабатываемой матрицы.

На рисунке ниже представлена функциональная схема предлагаемого устройства для возведения бинарной матрицы в квадрат.

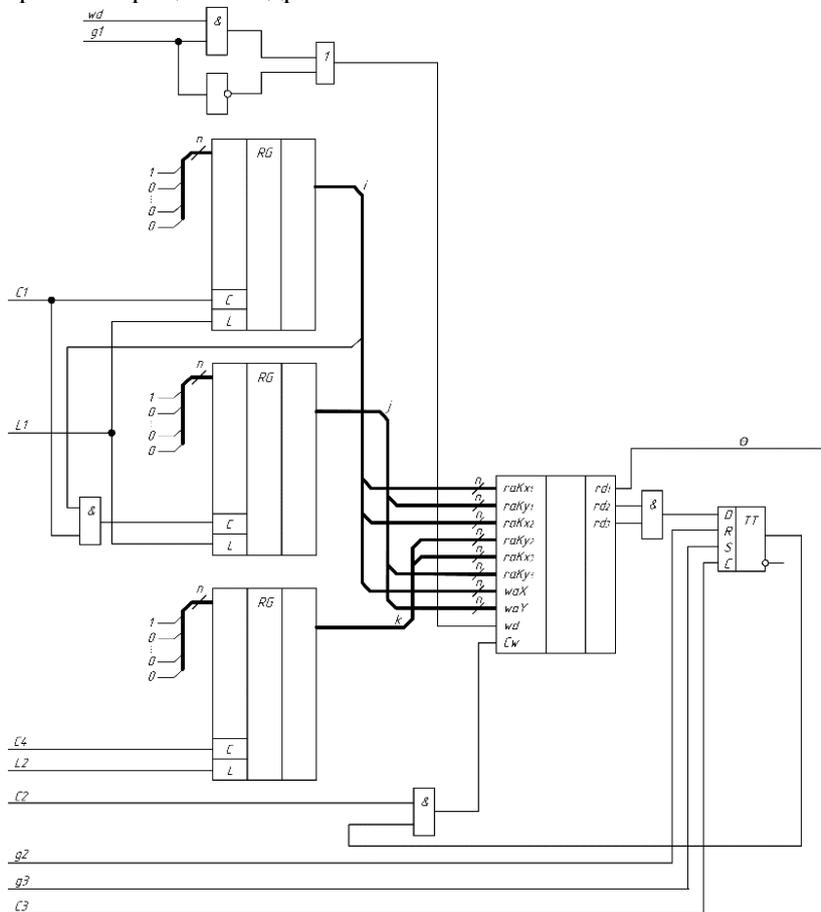


Рис. Функциональная схема предлагаемого устройства для возведения бинарной матрицы в квадрат

Был произведен расчет быстродействия предлагаемого итерационного устройства для возведения бинарной матрицы в квадрат в сравнении с устройством-прототипом. На основе полученных аналитических формул можно сделать вывод о том, что разработанное устройство позволяет сократить время возведения матрицы в квадрат в пределах 2,08 – 88,97 раз в зависимости от размера n [3].

В дальнейшей перспективе планируется проведение оценки аппаратной сложности устройства и оценка временных затрат в сравнении с программными инструментами умножения матриц на современных процессорах и видеокартах.

Литература

1. Гвоздева, С. Н. Математическая модель определения состава бинарных отношений и алгоритм умножения бинарных матриц / С. Н. Гвоздева // Известия Юго-Западного государственного университета. – 2021. – Т. 25, № 2. – С. 65-82. – DOI 10.21869/2223-1560-2021-25-2-65-82.
2. Жиронкин, А. В. Специализированное итерационное вычислительное устройство умножения бинарных матриц / А. В. Жиронкин, Э. И. Ватулин // Облачные и распределенные вычислительные системы в электронном управлении. ОРВС - 2023 : сборник трудов 4-й

международной научно-технической конференции, Переславль-Залесский, 28 ноября – 01 2023 года. – Курск: ЗАО «Университетская книга», 2024. – С. 110-112.

3. Гвоздева, С. Н. Оценка быстродействия устройства для возведения бинарной матрицы в квадрат / С. Н. Гвоздева // Обработка информации и математическое моделирование : Материалы Российской научно-технической конференции, Новосибирск, 22–23 апреля 2021 года. – Новосибирск: Сибирский государственный университет телекоммуникаций и информатики, 2021. – С. 23-31.

4. Патент РФ № 2744239. Устройство для возведения бинарной матрицы в квадрат, заявл. 05.07.2020, опубл. 04.03.2021, бюл. № 7

Панкратов Д.А., Андрианов Д.Е.

*Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
denis_pankratov2000@mail.ru*

Улучшение метода классификации микроструктур на основе топологической декомпозиции за счёт фильтрации компонент связности

В рамках автоматизированного анализа микроструктур материалов на основе данных оптической и электронной микроскопии существует важная научно-прикладная задача по созданию устойчивых методов классификации. Традиционные подходы, базирующиеся на анализе геометрических параметров, текстурных статистик или сегментации, часто демонстрируют недостаточную надёжность в условиях неидеальных данных, вариаций условий съёмки и высокой внутриклассовой изменчивости [1–3]. Методы глубокого обучения, которые показывают выдающиеся результаты в компьютерном зрении, требуют для обучения больших объёмов размеченных данных и значительных вычислительных ресурсов, что не всегда осуществимо в специализированных областях материаловедения [4, 5].

В качестве альтернативы, сочетающей устойчивость к артефактам и способность выявлять инвариантные структурные признаки, был предложен подход, основанный на методах топологического анализа данных [6, 7]. В частности, метод классификации микроструктур, использующий топологическую декомпозицию изображений, продемонстрировал свою перспективность [8]. Его ключевое преимущество заключается в описании изображения через иерархию персистентных гомологий, фиксирующих рождение, слияние и исчезновение компонент связности, что обеспечивает инвариантность к глобальным аффинным преобразованиям и устойчивость к шуму [9]. Экспериментальная проверка на репрезентативной выборке изображений криогелей поливинилового спирта, охватывающей вариации температуры синтеза и типа добавок [10], подтвердила конкурентоспособность метода, была достигнута точность классификации 80,61% [8].

Суть метода заключается в последовательном анализе пикселей изображения в порядке убывания их яркости. При обнаружении пикселя, яркость которого не превышает значения текущего порога и который не имеет соседей среди уже созданных компонент, формируется новая компонента. Она представляется матрицей, совпадающей по размерам с исходным изображением и изначально заполненной нулями. В позиции анализируемого пикселя значение устанавливается равным единице. Если рассматриваемый пиксель граничит по сторонам с уже существующей компонентой, он присоединяется к ней, и соответствующее значение в матрице компоненты увеличивается. Нумерация компонент ведётся в порядке их возникновения.

При соприкосновении областей, принадлежащих разным компонентам, происходит их объединение. Приоритет отдаётся компоненте, имеющей наибольшее количество ненулевых пикселей (наибольший размер). При этом значения поглощаемой (менее крупной) компоненты в её ненулевых позициях устанавливаются равными единице. После завершения этого итеративного процесса для формирования признакового описания все полученные компоненты группируются в кластеры с использованием алгоритма k -средних.

В ходе тестирования различных признаков, извлечённых в результате топологической декомпозиции, были отобраны следующие характеристики: общее количество кластеров компонент, количество кластеров, содержащих как поглощающие, так и поглощённые компоненты, а также аналогичные подсчёты для случаев, когда количество компонент в кластере превышает одну. Дополнительно учитывались количество поглощённых компонент, сгруппированных по размеру (числу пикселей), и количество поглощающих компонент, классифицированных по продолжительности их существования (интервалу яркостей).

В рамках данного исследования предлагается развитие метода классификации изображений на основе топологической декомпозиции, представленного в работе [8]. Усовершенствование направлено на фильтрацию повторяющихся поглощающих компонент.

В процессе декомпозиции по описанному алгоритму возможна ситуация, когда на одном уровне яркости одна компонента поглощает несколько других. При этом формально могут быть учтены несколько поглощающих компонент, которые, однако, имеют идентичные характеристики: яркость возникновения и интервал существования. В данной работе предлагается рассматривать такие дублирующиеся записи как избыточные и исключать их из итогового признакового пространства с целью повышения информативности описания.

Экспериментальная оценка на репрезентативной выборке изображений криогелей ПВС, состоящей из 2400 изображений, показала, что предложенная модификация повышает точность классификации с 80,61% до 88,21%. Этот результат свидетельствует о существенном улучшении дискриминативной способности усовершенствованного метода.

Литература

1. M. Stricker and A. Dimai, "Spectral covariance and fuzzy regions for image indexing," *Machine Vision and Applications* 10, 66–73 (1997). <https://doi.org/10.1007/s001380050060>
2. Колодникова Наталья Владимировна Обзор текстурных признаков для задач распознавания образов // Доклады ТУСУР. 2004. №1 (9).
3. Сакович Илона Олеговна, Белов Юрий Сергеевич Обзор основных методов контурного анализа для выделения контуров движущихся объектов // Инженерный журнал: наука и инновации. 2014. №12 (36).
4. X. Glorot and Y. Bengio, "Understanding the difficulty of training deep feedforward neural networks," *Journal of Machine Learning Research - Proceedings Track*, 9, 249–256 (2010).
5. Шутов, И. В. Применение глубоких сверточных нейронных сетей в задаче классификации изображений микросрезов криогелей поливинилового спирта / И. В. Шутов, И. И. Курочкин, О. Ю. Колосова // Информатика, управление и системный анализ : Труды V Всероссийской научной конференции молодых ученых с международным участием, Ростов-на-Дону, 06–08 июня 2018 года. – Ростов-на-Дону: Ростовский государственный экономический университет "РИНХ", 2018. – С. 470-478. – EDN ХТТJDN.
6. Еремеев С.В., Абакумов А.В., Андрианов Д.Е., Титов Д.В. Метод разложения изображения по топологическим признакам // Компьютерная оптика. – 2022. – Т.46, №6. – С. 939-947.
7. Carlsson E., Carlsson G., de Silva V. An Algebraic Topological Method for Feature Identification // *International Journal of Computational Geometry & Applications*. – 2006. – Vol. 16, № 4. – P. 291-314. – DOI: 10.1142/S021819590600204X.
8. Pankratov, D. A. Formation of Microstructure Image Features Based on Topological Decomposition / D. A. Pankratov, S. V. Eremeev // *Pattern Recognition and Image Analysis. Advances in Mathematical Theory and Applications*. – 2025. – Vol. 35, No. 3. – P. 387-396. – DOI 10.1134/S1054661825700269. – EDN XYOFIE.
9. Исследование топологической структуры изображений при использовании аугментации / С. В. Еремеев, А. В. Абакумов, Д. А. Панкратов, Б. А. Хавронин // *Геоинформатика*. – 2025. – № 1. – С. 72-78. – DOI 10.47148/1609-364X-2025-1-72-78. – EDN DBKJVI.
10. Изучение криоструктурирования полимерных систем. 27. физико-химические свойства криогелей поливинилового спирта и особенности их макропористой морфологии / В. И. Лозинский, Л. Г. Дамшквалн, Б. Л. Шаскольский [и др.] // *Коллоидный журнал*. – 2007. – Т. 69. – № 6. – С. 798-816. – EDN IBGVJJ.

Панов Е.А.¹, Еремеев С.В.²

магистрант, научный руководитель Еремеев С.В., *к.т.н, доцент*
Муромский институт (филиал) федерального государственного бюджетного
образовательного учреждения высшего образования «Владимирский государственный
университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264 г. Муром, Владимирской обл., ул. Орловская, д. 23
janurpanov@gmail.com¹, sv-eremeev@yandex.ru²

Моделирование и прогнозирование отказоустойчивости распределённых систем

Распределённые информационные системы являются основой современных цифровых платформ. Они активно используются в банковской сфере, электронной коммерции, госуслугах и промышленности, где критически важна их работа без перебоев. Даже кратковременные сбои могут приводить к серьёзным последствиям.

В связи с этим многие нуждаются в средствах, позволяющих оценивать и прогнозировать надёжность таких систем [1]. Целью данной работы является разработка прототипа программной платформы, позволяющей на основе телеметрии и параметров прогнозировать потенциальные сбои и поведение распределённого сервиса при различных нагрузках и отказах [2]. В работе предполагается реализация гибридного подхода, включающий вероятностные модели и методы машинного обучения. Модель будет обучаться на метриках, поступающих данных от сервисов распределённой системы. Инструменты для мониторинга были выбраны Prometheus и Grafana.

Отдельное внимание уделяется моделированию отказов и деградации компонентов системы. Для этого предполагается реализация сценария сбоев, включающий увеличение задержек запросов, отказ отдельных сервисов и ограничение ресурсов. Полученные данные будут использоваться для обучения модели прогнозирования, способной определять вероятность ухудшения системы.

В результате планируется реализовать прототип, способный выполнять прогноз деградации SLI-метрик, например, задержка времени (latency), уровень ошибок (error rate), доступность (availability) и визуализировать риски отказа на основе накопленных данных. Значимость работы заключается в возможности применить данный подход для оценки надёжности систем ещё до возникновения ошибок и сбоев, а также в анализе архитектурных решений в области отказоустойчивости.

Литература

1. Лаврищева Е.М., Пакулин Н.В., Рыжов А.Г., Зеленов С.В. Анализ методов оценки надёжности оборудования и систем. Практика применения методов // Труды ИСП РАН, Т. 30, №3, 2018, С. 99-120.
2. Проталинский О.М., Щербатов И.А., Ханова А.А., Проталинский И.О. Адаптивная система прогнозирования надёжности технологического оборудования объектов энергетики // Информатика и системы управления, №1(59), 2019, С. 93-105.

Парамонов Н.С.¹, Еремеев С.В.²

Магистрант, научный руководитель Еремеев С.В., к.т.н, доцент
Муромский институт(филиал) ФГБОУ ВО «Владимирский государственный
университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
paramonov678@gmail.com¹, sv-eremeev@yandex.ru²

Разработка системы интеграции IoT-устройств в корпоративные информационные системы без облачных зависимостей с фокусом на безопасной аутентификации

Российский рынок интернета вещей показывает быстрый рост: по данным TAdviser, в 2024 году объём промышленного сегмента превысил 150 млрд рублей (+11-15 %), сегмент NB-IoT вырос втрое по затратам, до 1,1 млрд рублей, прогноз на 2025-2026 годы - 12-18 % ежегодно благодаря импортозамещению и национальному проекту «Экономика данных» [1]. Однако подавляющее большинство решений построено на облачных платформах, что может создавать серьёзные риски: утечки данных, задержки передачи (>150 - 250 мс), зависимость от внешних провайдеров в условиях санкций и требований локализации [2].

Предлагаемая система автономна от данных угроз - регистрация, аутентификация и обмен данными происходят исключительно в изолированной корпоративной сети без доступа в общую сеть. Основные компоненты: офлайн-регистрация с подтверждением физического владения данным устройством через Serial и HMAC-чек микроконтроллеров, постквантовое начальное рукопожатие на основе Noise_XX + ML-KEM-1024 (Kyber) с аппаратной привязкой платы через eFuse, непрерывная ротация сеансовых ключей каждые 300 секунд или 300 пакетов для обеспечения прямой секретности (PFS) и безопасности после компрометации (PCS), периодическая проверка целостности прошивки на возможную компроментацию.

Новизна заключается в уникальной комбинации постквантовой стойкости, аппаратной привязки идентификатора и непрерывной ротации ключей на микроконтроллерах с ограниченными ресурсами (Seeed Studio XIAO ESP32-C6 и XIAO ESP32-S3, 4 - 8 МБ Flash). Анализ релевантных патентов (RU2695487C1, RU2767713C1, RU192192U1, US20170279620A1, US10171462) подтверждает отсутствие прямых аналогов - существующие решения либо используют облако, либо не обеспечивают достаточную защиту информации, либо не актуальны на нынешнее время.

Ключевые проблемы постквантовой криптографии (большие размеры ключей и шифротекстов, высокие вычислительные затраты на основе Learning with Errors (LWE), уязвимость к атакам по сторонним каналам) будут решаться в системе за счёт оптимизации кода и гибридных подходов. Предлагаемый алгоритм LACERT (Lightweight Autonomous Continuous Encryption with Refreshment Tokens - Легковесное Автономное Непрерывное Шифрование с Токенами Обновления) сочетает Noise_XX + ML-KEM + SLH-DSA, планируется достижение приближённого сходства по скорости и безопасности с чистым Kyber при снижении энергозатрат.

Система актуальна для промышленности, энергетики и объектов КИИ (Критическая информационная инфраструктура), где критичны суверенитет данных и низкая задержка.

Литература

1. TAdviser. Интернет вещей, IoT, M2M (рынок России). URL: [https://www.tadviser.ru/index.php/Статья:Интернет_вещей,_IoT_\(рынок_России\)](https://www.tadviser.ru/index.php/Статья:Интернет_вещей,_IoT_(рынок_России)) (дата обращения: 27.12.2025).
2. Palo Alto Networks. How to Secure IoT Devices in the Enterprise. URL: <https://www.paloaltonetworks.com/cyberpedia/how-to-secure-iot-devices-in-the-enterprise> (дата обращения: 27.12.2025).

*Парфенов Д.В., Ватулин Э.И.
Юго-Западный государственный университет
305040, г. Курск, ул. 50 лет Октября, 94*

Разработка программы для построения сеточных карт флоры Курской области

С каждым годом интерес человека к природе и вопросам экологии становится все больше. Люди изучают флору и фауну своего региона и страны в целом, заботятся о спасении видов, которые находятся под угрозой исчезновения или на грани вымирания, создают заповедники, организуют сбор средств на спасение различных видов животных и растений, состоят в волонтерских организациях по спасению окружающего мира. Координированной работе всех заинтересованных лиц могут помочь сеточные карты, которые будут информировать пользователя о частоте наблюдений какого-либо вида в различных районах региона. С их помощью можно будет проследивать динамику изменения численности определенного представителя флоры или фауны, прокладывать различные туристические маршруты и организовывать научные экспедиции. Картирование – описание чего-либо с помощью карт. Сеточное картирование – это метод, используемый в географии, экологии и социальных науках для визуализации и анализа пространственных данных. Он включает в себя деление территории на множество ячеек, образующих регулярную сетку, что позволяет анализировать данные по заданным ячейкам и выявлять пространственные закономерности. Разработанная программа позволит автоматизировать процесс построения сеточных карт с разным масштабом, что позволит в дальнейшем иметь представление о текущем состоянии и динамике флоры Курской области.

Для создания, редактирования, визуализации и анализа сеточных карт используется кроссплатформенная геоинформационная система QGIS [1], обладающая большим набором встроенных функций, плагинов и возможностью скачивания дополнительных модулей из Интернета. Но главным преимуществом этой системы является возможность автоматизации работы при помощи PyGIS [2] – Python-библиотеки и API, созданной специально для QGIS и позволяющей писать скрипты на языке Python для создания геопространственной информации. Соответственно главной проблемой является зависимость подобных скриптов от запуска в приложении QGIS.

Для разрабатываемой программы было принято решение создать графический дизайн и логику работы на языке C# [3] и запускать скрипты на выполнение внутри программы с указанием всех необходимых переменных системы и окружения. Для работы скриптов вне QGIS необходимо задать следующие переменные: PATH – путь к интерпретатору Python, распознающего конструкции PyGIS и к утилите, запускающей алгоритмы обработки геоданных, PYTHONPATH – путь к дополнительным каталогам для поиска импортируемых модулей и пакетов, PYTHONHOME – путь к стандартным библиотекам Python, QGIS_PREFIX_PATH – путь к корневому каталогу установки QGIS, QT_PLUGIN_PATH – переменная уровня графического фреймворка Qt [4], на котором построен весь интерфейс QGIS. Все директории, пути к которым указываются в данных переменных, автоматически устанавливаются при инсталляции данной системы.

Для управления параметрами сеточной карты и базой данных наблюдений (размер полигона, год наблюдений, временной интервал для наблюдений) планируется использовать конфигурационный файл, который будет создаваться и заполняться программой и в дальнейшем читаться скриптом. В качестве источника данных для анализа выступает широко известная платформа iNaturalist [5], позволяющая выполнить экспорт данных в формате .csv, в том числе путем применения к ним ряда фильтров (географический регион, диапазон дат, интересующие виды и т.п.). Для отображения карты области используется слой OSM Standart. Он представляет собой растровый картографический стиль (тайлы), создаваемый на основе данных OSM. Он предназначен для отображения подробной географической информации. Для экономии памяти используется только та часть карты, которая отображает Курскую область. Хранится она в растровом формате .tiff. Слои карты сохраняются в формате .gpkg. Это позволяет хранить их в читаемом для QGIS виде. Настройки дизайна слоя записываются в QML-файлах. Для отображения всех созданных слоев с нужным дизайном используется QGZ-

файл, который хранит ссылки на файлы со слоями и их дизайнами и отображает их в одном видимом пространстве. Следовательно, построение сеточной карты программой делится на 5 этапов:

1. Загрузка границ Курской области в формате .gpkg, карты области и базы данных наблюдений в виде CSV файла.
 2. Создание сетки по границам Курской области и её сохранение.
 3. Подсчет количества наблюдений в каждой ячейке, отрисовка полученного значения, создание градиента, сохранение слоя градиента.
 4. Добавление всех созданных слоев в один .qgz файл.
 5. Создание макета сеточной карты и легенды и конвертация в растровый формат или в PDF-файл.
- Пример построенной карты приведен на рисунке.

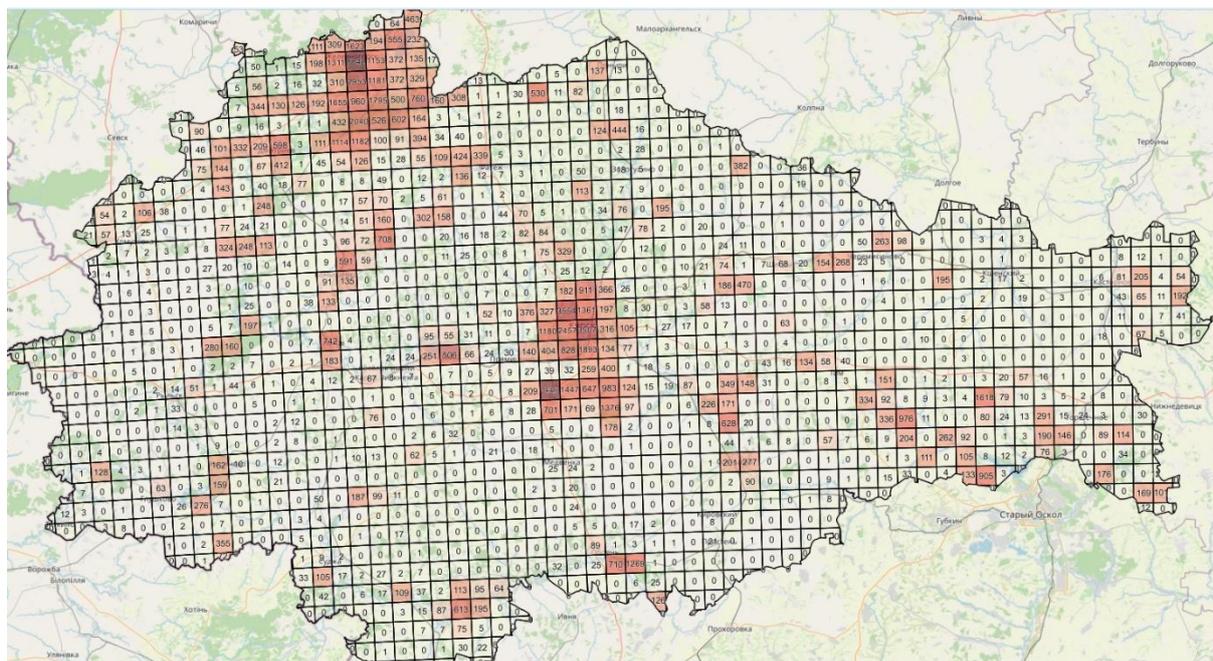


Рис. Пример картографирования флоры Курской области (цифра в ячейке – общее число наблюдений сосудистых растений, шаг сетки – 5x5 км)

Таким образом, созданная программа строит сеточные карты, но с предварительно заданными параметрами в файле скрипта, а не параметрами, заданными пользователем. Следовательно, следующий этап разработки – добавление возможности задавать параметры построения непосредственно в программе и настройка правильного и читабельного конвертирования файлов QGIS в общедоступные форматы.

Литература

1. Stack Overflow. Using QGIS in Python [Электронный ресурс]. URL: <https://stackoverflow.com/questions/79239625/using-qgis-in-python>
2. PyQGIS Developer Cookbook [Электронный ресурс]. URL: https://docs.qgis.org/3.40/en/docs/pyqgis_developer_cookbook/index.html
3. C# и .NET. Процессы [Электронный ресурс]. URL: <https://metanit.com/sharp/tutorial/18.1.php>.
4. Qt Documentation. Deploying Plugins [Электронный ресурс]. URL: <https://doc.qt.io/qt-6/deployment-plugins.html>.
5. Платформа iNaturalist [Электронный ресурс]. URL: <https://www.inaturalist.org/>.