

Абрамов О.А.

Научный руководитель: д.т.н., доцент А.А. Орлов

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

Исследование деревьев Хеффдинга как алгоритма инкрементного обучения

В последние десятилетия научное сообщество активно занимается разработкой алгоритмов машинного обучения, способных адаптироваться к изменяющимся данным [1]. В связи с появлением больших объемов данных и их динамическим характером, внимание уделяется методам, позволяющим обучать модели на потоке данных, при этом требуется быстрая адаптация к изменениям в данных.

Один из таких методов, известный как деревья Хеффдинга, представляет собой механизм классификации данных, который допускает инкрементное обучение [2].

Деревья Хеффдинга представляют собой метод классификации потоков данных, который строит дерево решений на основе стратегии выбора оптимального разбиения при поступлении каждого нового наблюдения. Основной принцип заключается в том, что для каждого узла дерева выбирается признак, по которому наилучшим образом можно разделить поток данных. Для этого используется критерий Хеффдинга, который позволяет оценить, насколько хорошо текущее разбиение адаптировано к поступающим данным [3].

Было проведено исследование изменения точности дерева Хеффдинга по мере поступления данных с использованием генератора данных SEAGenerator из библиотеки scikit-multiflow. Этот генератор создает поток данных с двумя классами, что предназначено для проверки алгоритмов машинного обучения на потоках данных. Для обучения модели было выбрано дерево Хеффдинга из той же библиотеки. Для каждого нового наблюдения модель обновлялась с помощью метода `partial_fit`. После каждого обновления модели оценивалась ее точность на текущем объеме данных, вычисляемая как доля правильных предсказаний по сравнению с фактическими значениями. Зависимость точности модели от времени (количества поступивших данных) представлена на рисунке 1.

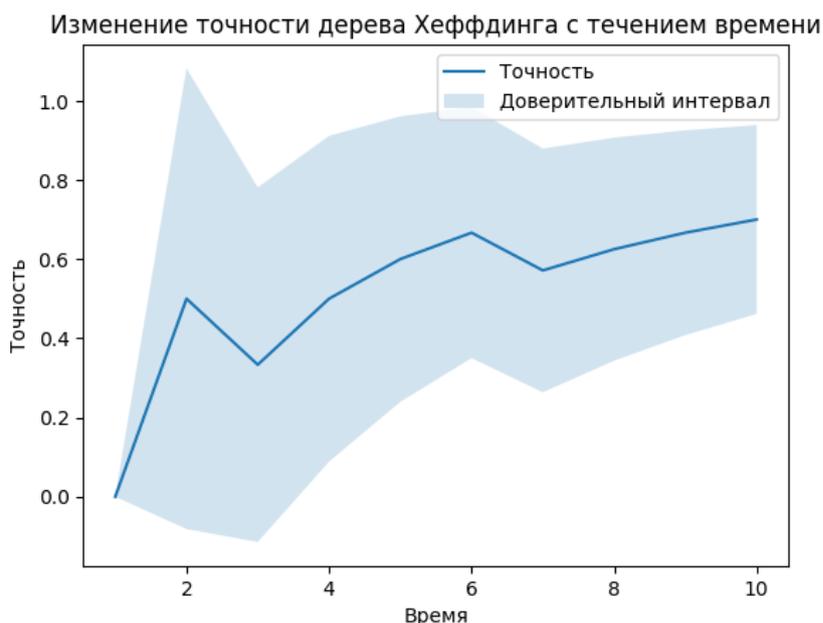


Рис. 1. Зависимость точности модели от времени

Точность модели представлена в виде линии, а доверительный интервал представлен в виде закрашенной области вокруг этой линии. Доверительный интервал показывает диапазон значений, в котором, с определенной вероятностью (в данном случае, 90%), находится среднее значение точности модели. Уменьшение ширины доверительного интервала может свидетельствовать о повышении уверенности в предсказаниях модели.

Исследование деревьев Хефдинга как алгоритма инкрементного обучения позволяет понять их принципы работы, преимущества и применимость на практике. Они представляют собой важный инструмент для обработки потоков данных в реальном времени и могут эффективно решать задачи классификации и регрессии, требующие быстрой адаптации к изменяющимся условиям.

Литература

1. Абрамова, Е.С. Возможности использования инкрементного обучения нейронной сети / Е.С. Абрамова, А.А. Орлов, К.В. Макаров // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». – 2021. – Т. 21, № 4. – С. 19–27. DOI: 10.14529/ctcr210402
2. Ade R.R., Deshmukh P.R. Methods for Incremental Learning: A Survey. International Journal of Data Mining & Knowledge Management Process, 2013, vol. 3, pp. 119–125. DOI: 10.5121/ijdkp.2013.3408
3. Kumar, Arvind et al. A Survey on Hoeffding Tree Stream Data Classification Algorithms. CPUH-Research Journal: 2015, 1(2), 28-32.

Астафьев А.С.

Научный руководитель: А.В. Астафьев

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

Разработка системы автоматического распределения комплектующих на основе данных номенклатуры при помощи метода искусственного интеллекта «Word Embeddings»

Целью работы является разработка системы автоматического распределения комплектующих на основе данных номенклатуры при помощи метода искусственного интеллекта «Word Embeddings». В связи с тем, что даже на современных производствах встречаются проблемы с ошибками распределения по складам, эта работа является актуальной. Одной из основных проблем является отсутствие данного изделия в базе данных, иногда, не смотря на то, что оно уже поступало на производство. Эта проблема связана с человеческим фактором на стороне поставщика или с поступлением на производство совершенно нового изделия. В связи с этим работник производства ответственный за распределение может допустить ошибку и отправить тот же ресурс на разные склады, что повлечет за собой затрудненный доступ к этому изделию и проблему производственной маршрутизации.

Другой же проблемой распределения комплектующих является человеческий фактор. Даже если наименование изделия на складе и в ведомости новоприбывших изделий идентичны, человек может допустить случайную ошибку и указать совершенно другой склад.

Еще одной проблемой именно ручного распределения комплектующих по складам является времязатратность данного процесса.

В связи с таким количеством и качеством проблем возникает задача оптимизации процесса путем создания системы распределения комплектующих на основе данных номенклатуры при помощи искусственного интеллекта для нивелирования человеческого фактора и уже имеющихся ошибок по распределению.

Для достижения поставленного результата необходимо подготовить данные для обучения, разработать архитектуру модели нейронной сети, обучить нейронную сеть, создать систему десктопного приложения.

В ходе данной работы было выявлено несколько положительных сторон использования ИИ в системе распределения:

- Увеличение эффективности и точности работы. Искусственный интеллект способен обрабатывать и анализировать большие объемы данных за краткое время. Это позволяет повысить эффективность работы и снизить вероятность ошибок.
- Автоматизация рутинных задач. Рутинные задачи, такие как сортировка и обработка данных, могут быть автоматизированы с помощью искусственного интеллекта. Это позволяет сократить время и энергию, затрачиваемые на выполнение таких задач, и освободить ресурсы для выполнения более важных задач.
- Быстрое адаптивное к изменениям. Искусственный интеллект может быстро адаптироваться и обучаться новым данным и ситуациям. Это позволяет системе адекватно реагировать на изменения и принимать решения на основе актуальной информации. Также модель нейронной сети можно модернизировать в зависимости от входных параметров. Если у изделия появятся новые параметры в базе данных помимо наименования, то можно адаптировать систему и под эту работу.
- Преимущество перед алгоритмами поиска по базе данных. Поиск по большому количеству данных в базе данных может нагрузить систему предприятия особенно если тех-ника предприятия не предназначена для средних или больших нагрузок. При встрече алгоритмом совершенно неизвестного в базе данных изделия, либо произойдет то, что алгоритм не сможет определить изделие на склад или, если поиск неточный то, определит в несколько складов

одновременно. ИИ в свою очередь не делает запроса на сервер базы данных, чем не создает нагрузки, и не ищет среди огромного количества данных, а используя математику заложенную в «весах и алгоритмах» выдает ответ, также искусственный интеллект способен определить вероятность определения изделия на склад, что, в случае вероятности ниже 80%, склад всё таки будет выбран или работник, запустивший процесс распределения, может за-метит несостыковку и перераспределить в другой склад. В последнем случае можно сохранять данные «несостыковки» для дальнейшего переобучения ИИ.

Использование искусственного интеллекта в теме распределения по наименованию не имеет известных аналогов, так как зачастую искусственный интеллект используют для предсказания спроса, управления поставок и эффективного планирования. Схожим по действию нейронной сети, классифицирующей по наименованиям, можно разве что выявить алгоритмы нечеткого поиска, «Расстояние Левенштейна», схожих с ним алгоритмов, методы баз данных. Все эти методы не показали достаточно производительности перед методом «Word Embeddings». Архитектура нейронной сети представлена на рисунке 1.

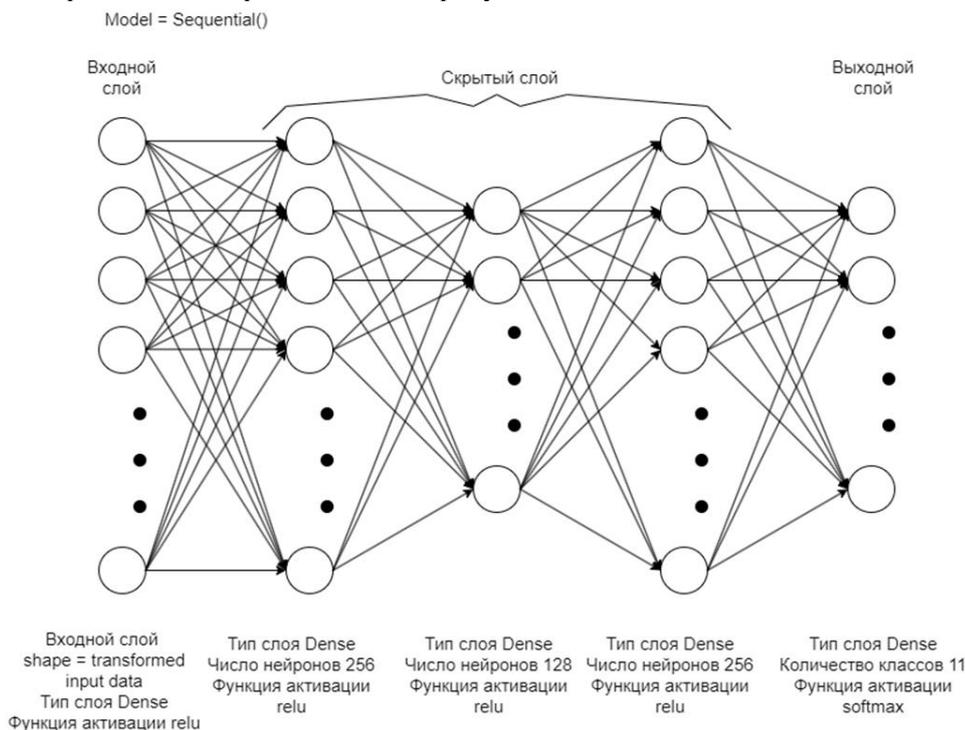


Рис. 1. Модель нейронной сети с описанием слоев.

В ходе работы была создана модель нейронной сети: библиотека keras для создания нейронной сети. Можно использовать различные слои, например, слои Dense (полносвязные слои), слои Embedding (для преобразования текста в векторное представление), и другие слои. Количество слоев и нейронов в них первоначально подбирается интуитивно, исходя из результатов и проведенных экспериментов подбирается подходящая архитектура. В данном проекте будут использовано последовательное построение слоев при помощи инструмента Sequential. Затем следует функция потерь (loss function) и оптимизатор (optimizer) для обучения модели. После проведения некоторых экспериментов было принято решение использовать оптимизатор Adam.

Литература

1. Kusner M. et al. From word embeddings to document distances //International conference on machine learning. – PMLR, 2015. – С. 957-966.
2. Bakarov A. A survey of word embeddings evaluation methods //arXiv preprint arXiv:1801.09536. – 2018.

Баринов М.В.

Научный руководитель: к. т. н., доц. Рыжкова М.Н.

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

Чат-бот для обучения программированию

Целью данной работы является создание чат-бота для обучения основам программирования на языке Python. Для достижения данного результата были определены следующие задачи: разработка и обучение нейронной сети для генерации уникальных заданий, создание базы данных для хранения данных пользователя и подключение их к чат-боту.

Актуальность проекта обоснована по двум сферам:

- актуальность обучению программированию,
- актуальность обучения с помощью чат-ботов.

Актуальность использования чат-ботов обоснована тем, что данная ниша компьютерных технологий всё ещё набирает популярность, и, как показал анализ текущей ситуации по применению чат-ботов в образовании, подобных чат-ботов для обучения не так много. Что касается актуальности в сфере обучения программированию, то нельзя не отметить, что на большинстве онлайн ресурсов для обучения представлены заранее заготовленные задания, ответы на которые уже зачастую лежат в сети. Для снижения вероятности использования уже готовых ответов, некоторые задания будут генерироваться при помощи нейронной сети.

При поиске аналогов были выделены следующие боты: @ProgrammingFAbot. Этот бот учит программированию, помогает с терминологией и может рассказать интересные факты из IT сферы; @KotlinBasicsBot. Данный бот предназначен для изучения языка программирования Kotlin. Бот имеет удобное меню с выбором конкретного урока. Также в программе отслеживается прогресс по работе в нём. Из онлайн ресурсов можно выделить такой сайт как stepik, так как он предоставляет большое количество авторских курсов. На основе данных курсов, материала представленных в них и методах обучения, были сформулированы требования к разрабатываемому чат-боту.

Чат-бот имеет несколько разделов, включающих в свою очередь подразделы. Разделы бота:

- Профиль пользователя,
- Меню выбора тем (переменные, ввод-вывод данных, типы данных, условный оператор, циклы). Перечисленные темы также подразделяются на уроки.

Помимо самого бота к системе обучения должны быть подключены: база данных заданий (тестовая часть, задания типа вопрос-ответ) и нейронная сеть, генерирующая другой тип заданий (анализ работы кода).

Для обучения нейронной сети был составлен набор данных, включающий в себя коды простых программ на Python. Для реализации нейронной сети, способной генерировать код программ для задач было решено выбрать тип рекуррентных нейронных сетей (далее РНС). Обоснования для этого были следующие преимущества данного типа нейронных сетей: РНС способны учитывать зависимости между элементами кода, что необходимо для правильной генерации кода; При наличии меньшего числа параметров, РНС могут обучаться быстрее, особенно на небольших объёмах данных; РНС широко применяются для задач генерации текста, что включает в себя и генерацию программного кода.

Существующая в проекте база данных содержит в себе задания, различающиеся для каждой из тем. Помимо самих заданий, в базе данных сохраняется прогресс пользователей по прохождению курса — отмечаются пройденные уроки и темы, подсчитывается общий балл за прохождение урок/темы/курса.

Реализация такого чат-бота позволит обучать школьников азам программирования на языке Python, обрабатывать простейшие коды и операции.

Гусев М.А.

Научный руководитель к.т.н., доцент А.А. Белов

Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых».

Россия, 602264, Владимирская область, г. Муром, ул. Орловская, д.23,

e-mail: g.max01@mail.ru

Будущее вычислений в масштабах атома: пределы и перспективы сокращения техпроцессов

Ключевым элементом практически каждой вычислительной схемы является транзистор. Это полупроводниковый элемент, который служит для управления токами. Из транзисторов собираются основные логические элементы, а на их основе создаются различные комбинационные схемы и уже непосредственно процессоры.

Чем больше транзисторов в процессоре — тем выше его производительность, ведь можно поместить на кристалл большее количество логических элементов для выполнения разных операций. Чем больше транзисторов в процессоре — тем выше его производительность, ведь можно поместить на кристалл большее количество логических элементов для выполнения разных операций.

В соответствии с законом, сформулированным американским инженером и изобретателем Гордоном Муром в 1975 году, количество транзисторов в интегральных микросхемах удваивается примерно каждые два года. Это наблюдение оправдалось на протяжении многих лет и послужило мощным стимулом для развития полупроводниковой индустрии.

Однако фундаментальные физические ограничения, связанные с квантовой природой явлений на наноуровне, в конечном итоге приведут к снижению темпов миниатюризации и возможному переходу к новой парадигме. Уже сейчас актуальны исследования альтернативных материалов и технологий, в том числе квантовых вычислений.

Так же закон Мура имеет физические ограничения. В следующем десятилетии ожидается, что размеры транзисторов перестанут сокращаться вдвое каждые два года. Возможно, будет замедление темпов или даже наступит период стагнации.

Однако в настоящее время физические ограничения, такие как эффект туннельных токов, не позволят в полной мере продолжить миниатюризацию планарных транзисторов ниже 5 нм. Для дальнейшего уплотнения элементов на кристалле разрабатываются 3D-структуры и исследуются новые материалы.

Эффект туннельных токов - это явление туннельного проникновения электронов через потенциальный барьер под действием электрического поля.

В транзисторах это проявляется следующим образом: между затвором транзистора и каналом проводимости находится тонкий слой затворного диэлектрика (оксид кремния SiO₂). Этот слой представляет собой потенциальный барьер для электронов. При легировании затвором формируется разность потенциалов по обе стороны барьера. Благодаря этому некоторые электроны способны преодолевать барьер не за счет тепловой энергии, а путем туннельного перехода. Этот поток электронов, проходящий "сквозь" барьер, и формирует туннельный ток.

При сокращении толщины оксида вероятность туннеля растет, а токи увеличиваются до критических значений.

При сокращении толщины затворного оксида транзистора ниже 1-2 нанометров происходит нежелательный ток утечки за счет туннелирования электронов через этот оксид. Это приводит к рассеиванию энергии и тепла, а также нарушению функционирования транзистора.

Процесс 5 нм сейчас можно считать оптимальным, так как он обеспечивает прирост мощности при контролируемых технологических возможностях.

В перспективе ожидается переход к квантовым вычислениям, способным кардинально изменить вычислительные технологии. Однако реализация этого предполагает решение множества фундаментальных задач.

Дальнейшее развитие производства микрочипов будет связано с поиском новаторских подходов к элементной базе, учитывающих квантовую природу явлений на наноуровне.

Денисова П.А., Привезенцева К.С, Короткая А.С.

Научный руководитель: А.В. Астафьев

Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»

602264, г. Муром, Владимирская обл., ул. Орловская, 23

E-mail: polina.denisova.2013@gmail.com

Применение метода главных компонент на примере задачи классификации MNIST

В современном мире очень часто приходится работать с большими объёмами данных. Для их анализа используется многомерное представление, но для человека работать с таким видом информации очень сложно. Поэтому появилась идея уменьшения размерности данных, которая позволяет намного легче найти их зависимость, но при этом происходит снижение точности. Исходя из этого, тема исследования является актуальной научно-технической задачей.

Целью исследования является применение метода главных компонент на примере задачи классификации MNIST.

Постановка задачи: существует такой набор данных MNIST, который представляет огромное количество рукописного написания цифр от 0 до 9. Наша задача оценить какие из пикселей 8·8 являются информативными, а какие нет, также попробовать применить метод главных компонент для снижения размерности данных.

Каждый символ представляет собой матрицу 8·8 пикселя, каждый из которых отвечает за яркость в градации серого от 0 до 255:

$$X = \begin{matrix} & X_{00} & X_{01} & \dots & X_{07} \\ X & X_{10} & X_{11} & \dots & X_{17} \\ & \vdots & \vdots & \ddots & \vdots \\ & X_{70} & X_{71} & \dots & X_{77} \end{matrix}$$

К набору данных MNIST применяются специальные математические преобразования. После этого уже используется метод главных компонент. Для анализа количества нужной информации, которая хранится в каждом столбце матрицы, применяется метод главных компонент с сохранением 95 % полезной информацией. В итоге получилось, что количество столбцов с 64 снизилось до 29, при этом точность равна 96,94 %. Информативность каждого столбца представлена на рисунке 1.

```
array([0.14890594, 0.13618771, 0.11794594, 0.08409979, 0.05782415,
       0.0491691 , 0.04315987, 0.03661373, 0.03353248, 0.03078806,
       0.02372341, 0.02272697, 0.01821863, 0.01773855, 0.01467101,
       0.01409716, 0.01318589, 0.01248138, 0.01017718, 0.00905617,
       0.00889538, 0.00797123, 0.00767493, 0.00722904, 0.00695889,
       0.00596081, 0.00575615, 0.00515158, 0.0048954 ])
```

Рис. 1. Информативность каждого столбца

При просмотре рисунка 1 можно заметить, что первый столбец несёт в себе больше информации, чем второй.

После использования метода стало меньше данных, но всё равно тяжело для анализа. Поэтому снова применяется метод главных компонент, только теперь указав, что будет две компоненты. В ходе этого получилось, что количество столбцов с 29 снизилось до 2, а точность стала 60,83 %. Информативность двух столбцов представлена на рисунке 2.

```
array([0.14890594, 0.13618771])
```

Рис. 2. Информативность двух столбцов

Проанализировав рисунок 2 можно увидеть, что большая часть информации была убрана, поэтому точность так сильно снизилась.

Заключение: В ходе применения метода главных компонент к набору данных MNIST, была уменьшена размерность данных с 64 столбцов до 2, при этом точность снизилась до 60,83%. Благодаря этому методу произошёл переход от многомерного представления данных к линейному, что значительно облегчило работу с ними.

Работа выполнена в рамках гранта РФФ №24-21-00360.

Ежков Д.А., Ерофеев А.Р., Карпычева Л.И.
 Научный руководитель: к.т.н., доцент А.В. Астафьев
 Муромский институт (филиал) федерального государственного образовательного
 учреждения высшего образования «Владимирский государственный университет
 имени Александра Григорьевича и Николая Григорьевича Столетовых»
 602264, г. Муром, Владимирская обл., ул. Орловская, 23
 E-mail: ejkov.dmitrij@yandex.ru

Использование подходов AutoML для решения задач классификации

На данный момент времени, машинное обучение является технологией, применимой во многих областях человеческой деятельности. Однако высокий порог входа препятствует применению такого типа систем. Для решения этой проблемы возможно использование методов AutoML (Automated machine learning — автоматизированное машинное обучение). В связи с этим исследование методов AutoML является актуальной научно-технической задачей.

Целью работы является исследование подходов AutoML при решении задач классификации. Для достижения поставленной цели необходимо выполнить следующие задачи:

- 1) Определение задачи классификации, используемой для изучения методов AutoML.
- 2) Создание модели для решения задачи классификации при помощи стандартных методов.
- 3) Создание модели нейронной сети для решения поставленной задачи классификации, используя AutoML.
- 4) Сравнение результатов полученных моделей.

В качестве задачи классификации в исследовании рассматривается определение тригонометрической функции (синуса, косинуса или тангенса). по набору точек, являющихся частью графика соответствующей функции.

Набор данных для обучения получен путем генерации 5000 точек, координата x которых — случайное значение в диапазоне от -25π до 25π . Данный набор распределен на срезы по 10 последовательных точек. Итоговый набор разделен на обучающую выборку (80% данных) и выборку валидации (20% данных). Таким же образом сгенерирован тестовый набор.

При определении эффективности AutoML необходимо его сравнение со стандартными методами. Для этого вручную была создана архитектура нейросети, и обучена соответствующая модель. Результаты представлены в таблице 1.

Таблица 1 — Архитектура нейронной сети

Архитектура	Время обучения, с	Количество ошибок, %
Входной слой (20 нейронов, Softmax) Полносвязный слой (10 нейронов, Softmax) Выходной слой (3 нейрона, Softmax)	22,32	38,8

Для исследования AutoML была выбрана библиотека autokeras, поскольку она основана на одной из популярных библиотек для машинного обучения — keras, что позволяет просматривать структуру получающейся нейросети. При использовании autokeras, при создании модели, необходимо указать количество попыток на создание архитектуры. В работе используется по 5 попыток. Для того, чтобы компенсировать влияние случайного распределения начальных весов на результаты работы, каждая получаемая модель заново обучается на тех же данных, но с новыми начальными весами. Процесс повторного обучения повторяется по 10 раз на архитектуру. В каждой полученной модели входной слой состоит из 20 нейронов, а выходной слой — из 3 нейронов с функцией активации Softmax (что соответствует входным и выходным данным). Скрытые слои, время обучения и количество ошибок каждой модели представлены в таблице 2.

Таблица 2 — Архитектуры нейронных сетей, созданные autokeras

Архитектура	Время обучения, с	Количество ошибок, %		
		Минимальное	Среднее	Максимальное
Полносвязный слой (32 нейрона, ReLU) Полносвязный слой (512 нейронов, ReLU) Полносвязный слой (32 нейрона, ReLU)	100	11,3	34,8	59
Полносвязный слой (32 нейрона, ReLU) Полносвязный слой (1024 нейрона, ReLU)	98	8,2	19,8	27,8
Полносвязный слой (512 нейронов, ReLU) Полносвязный слой (512 нейронов, ReLU)	177	25,8	31,2	34,7
Полносвязный слой (1024 нейрона, ReLU) Полносвязный слой (32 нейрона, ReLU)	107	37,2	30,5	32,8
Полносвязный слой (1024 нейрона, ReLU) Полносвязный слой (1024 нейрона, ReLU) Полносвязный слой (64 нейрона, ReLU)	343	2,3	11,5	28,7

Таким образом, методы AutoML позволяют добиться результатов, сопоставимых с результатами моделей, созданных вручную, при этом значительно снижая трудозатраты и порог вхождения человека.

Работа выполнена в рамках гранта РФФИ №24-21-00360.

Ежков Д.А., Ерофеев А.Р., Карпычева Л.И.
 Научный руководитель: к.т.н., доцент А.В. Астафьев
 Муромский институт (филиал) федерального государственного образовательного
 учреждения высшего образования «Владимирский государственный университет
 имени Александра Григорьевича и Николая Григорьевича Столетовых»
 602264, г. Муром, Владимирская обл., ул. Орловская, 23
 E-mail: ejkov.dmitrij@yandex.ru

Использование подходов AutoML для решения задач регрессии

В настоящее время точность моделей нейронных сетей, разработанных человеком, достигает высоких показателей и разработка более точных моделей требует всё большего количества ресурсов. Для решения этой проблемы используются методы AutoML (Automated machine learning — автоматизированное машинное обучение). В связи с этим исследование методов AutoML является актуальной научно-технической задачей.

Целью работы является исследование подходов AutoML при решении задач регрессии.

Для достижения поставленной цели необходимо выполнить следующие задачи:

- 1) Формулировка задачи регрессии, используемой для изучения подходов AutoML.
- 2) Ручное создание модели нейронной сети для решения поставленной задачи регрессии.
- 3) Создание модели нейронной сети для решения поставленной задачи регрессии, используя AutoML.
- 4) Сравнение результатов полученных моделей.

В качестве задачи регрессии в исследовании будем рассматривать линейную функцию двух переменных:

$$f(x, y) = x + 2y + 3.$$

Набор данных для обучения получен путем определения значения функции $f(x, y)$ по 10 000 случайных входных данных. Полученный набор данных разделен на обучающую выборку и выборку валидации в пропорциях 80% на 20%. Аналогично сгенерирован тестовый набор данных, но меньшего объема.

В работе эффективность нейронной сети, полученной методами AutoML, определяется путём сравнения с моделью, разработанной стандартными методами. Информация о нейросети, созданной вручную в таблице 1.

Таблица 1 — Архитектура нейронной сети

Архитектура	Время обучения, с	Значение функции потерь
Входной слой (2 нейрона)	8,6	5,5
Полносвязный слой (5 нейронов)		
Полносвязный слой (5 нейронов)		
Полносвязный слой (5 нейронов)		
Выходной слой (1 нейрон)		

Для исследования AutoML была выбрана библиотека autokeras, поскольку она позволяет получать обученные модели в виде объектов библиотеки keras, благодаря чему возможно изучение структуры нейросети.

Перед созданием модели в библиотеке autokeras задается количество попыток для определения наилучшей архитектуры нейросети. В работе для каждого запуска указано количество, равное 5. Затем, в целях тестирования полученных архитектур, для каждой из моделей произведено 10 тестов, в ходе которых не используются веса, полученные с помощью AutoML. Это позволяет исключить фактор случайности при распределении начальных весов нейросети во время оценки полученной архитектуры. Результаты для 3 запусков autokeras и соответствующих тестов приведены в таблице 2.

Полученные результаты показывают, что методы AutoML позволяют получить результаты, даже превосходящие результаты модели, полученной традиционными методами (так,

минимальное значение функции потерь, полученное с autokeras — значительно меньше, чем у модели, созданной вручную).

Таблица 2 — Результаты обучения нейронной сети с AutoML

Архитектура	AutoML		Значение функции потерь для 10 моделей с такой же архитектурой		
	Время обучения, с	Значение ф-ции потерь	Минимальное	Среднее	Максимальное
Входной слой (2 нейрона) Полносвязный слой (32 нейрона) Полносвязный слой (32 нейрона) Выходной слой (1 нейрон)	95	0,404	1,029	4,034	10,605
Входной слой (2 нейрона) Полносвязный слой (32 нейрона) Полносвязный слой с включенным dropout (32 нейрона) Выходной слой (1 нейрон)	93	14361	13450	16593	25629
Входной слой (2 нейрона) Полносвязный слой (1024 нейрона) Полносвязный слой (32 нейрона) Выходной слой (1 нейрон)	103	29,9	0,51	0,58	0,68

Таким образом, хоть время обучения моделей и значительно возрастает, AutoML позволяет получить лучшие результаты при использовании меньшего количества человеческих ресурсов, при этом уровень вхождения в машинное обучение значительно снижается.

Работа выполнена в рамках гранта РФФИ №24-21-00360.

Ерофеев А.Р., Карпычева Л.И., Астафьева О.С., Ежков Д.А.
Научный руководитель: к.т.н., доцент Астафьев А.В.
Муромский институт (филиал) федерального государственного образовательного
учреждения высшего образования «Владимирский государственный университет
имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
E-mail: alexei_murom@mail.ru

Подсистема обработки информации от радиоустройств для обучения интеллектуального модуля позиционирования

В настоящее время идет быстрое развитие технологий передачи информации, с помощью радиоустройств. Самым распространенным из таких является Wi-Fi маршрутизатор (от англ. router). Маршрутизатор обладает функцией беспроводной связи, что позволяет передавать информацию не имею физического подключения к нему. Но его можно использовать и в других целях. Например, для позиционирования человека в помещении. Таким образом можно решить проблему точного определения местонахождения человека в помещении, что в свою очередь может улучшить системы умного дома или навигации.

Целью работы является разработка подсистемы обработки информации от радиоустройства для обучения интеллектуального модуля. Главными преимуществами данной системы будут легкая и дешевая внедряемость, а также объединение устройств передачи информации и позиционирования в одно.

Wi-Fi маршрутизатор является радиоустройством и работает на основе радиоволн. А радиоволны имеют такие характеристики как значения фаз и амплитуд. Именно на основе значений фаз им амплитуд можно производить позиционирование.

В стандарте Wi-Fi IEEE 802.11n появилось такое понятие как информация о канале связи (Channel State Information, CSI) – это подробная информация о том, как распространяется сигнал в пространстве, в том числе и значения фаз и амплитуд сигнала. В CSI значения фаз и амплитуд представлены в виде комплексного числа. Для извлечения комплексного числа, хранящего значения фаз и амплитуд, используется программное обеспечение «Atheros – Tool» [1].

Показатели значений фаз и амплитуд [2] не имеют явной зависимости с присутствием человека в пространстве. Поэтому был выбран метод нейронной сети, которая и будет предсказывать находится ли человек в измеряемой области или нет. Структура нейронной сети представлена на рисунке 1.

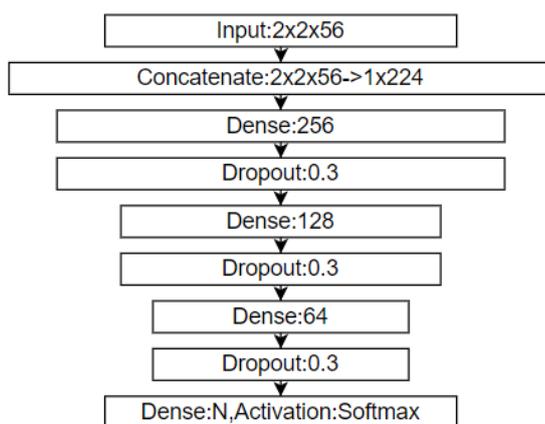


Рис. 1 – Структура нейронной сети

Количество нейронов на входном слое определяется с помощью произведения количества принимающих и передающих антенн, количества поднесущих и количества принимаемых значений для обучения. Внутренние слои состоят из полносвязных слоев с количеством нейронов от 256 до 64. Так же для борьбы с переобучением используется слой

«Dropout» со значением 0.3. На выходе нейронной сети находится полносвязный слой с функцией активации Softmax. Количество нейронов соответствует количеству позиций измерений. Обученная модель нейронной сети должна предсказывать положение человека в пространстве на основе загружаемых в нее значений фаз.

Для проведения экспериментов было необходимо произвести замеры в исследуемой зоне. Для этого человек принимающий участие в эксперименте должен находиться в разных местах исследуемой зоны, пока передаётся сигнал от Wi-Fi маршрутизатора. После проведения замеров полученные результаты были загружены в нейронную сеть. По завершению обучения, нейронная сеть научилась предсказывать нахождение человека в исследуемой зоне с точностью от 87.34% до 94.01%. Полученные данные представлены в таблице 1.

Таблица 1 – Результаты эксперимента

№	Параметры	Обучающая выборка				Тестовая выборка			
1	Количество эпох:300 Размер батча: 1000 Количество слоев: 1	8500	98.98	99.37	99.17	2500	91.59	93.98	92.79
2	Количество эпох:300 Размер батча: 1000 Количество слоев: 1	8000	98.52	99.13	98.87	2000	90.45	93.29	92.17
3	Количество эпох:500 Размер батча: 200 Количество слоев: 2	8000	97.28	98.65	98.12	2000	90.17	93.17	91.42
4	Количество эпох:500 Размер батча: 200 Количество слоев: 2	8500	96.15	98.67	97.89	2500	87.34	93.36	91.61
5	Количество эпох:500 Размер батча: 1000 Количество слоев: 2	8000	98.56	99.14	98.94	2000	91.24	94.01	92.38

Представленная подсистема имеет достаточно высокую точность позиционирования, но не было проведено исследований влияния внешних факторов на работу подсистемы, такие как дым, пыль и другие источники радиоволн.

Данная работа выполнена при финансовой поддержке гранта Российского научного фонда, проект № 24-21-00360

Литература

1. Yaxiong Xie, Zhenjiang Li, and Mo Li. 2015. Precise Power Delay Profiling with Commodity WiFi. In Proceedings of the 21st Annual International Conference on Mobile Computing and Networking (MobiCom '15). ACM, New York, NY, USA, 53-64. DOI: <http://dx.doi.org/10.1145/2789168.2790124>

2. A. V. Astafiev, A. L. Zhiznyakov, A. A. Zakharov and D. G. Privezentsev, "Algorithm for Preliminary Processing Channel State Information of the WIFI Communication Channel for Building

Indoor Positioning Systems,” 2022 24th International Conference on Digital Signal Processing and its Applications (DSPA), 2022, pp. 1-4, doi: 10.1109/DSPA53304.2022.9790751.

Карпычева Л.И., Ерофеев А.Р., Астафьева О.С., Ежков Д.А.
Научный руководитель: к.т.н., доцент кафедры ФПМ А. В. Астафьев
Муромский институт (филиал) федерального государственного образовательного
учреждения высшего образования «Владимирский государственный университет
имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
E-mail:luba060802@gmail.com

Подсистема обработки визуальной информации для обучения интеллектуального модуля позиционирования

В настоящее время системы умных домов, промышленной безопасности и прочие предъявляют всё большие требования к алгоритмам локализации внутри помещения, не нарушая его конфиденциальность. С точки зрения промышленной безопасности, использование алгоритмов локализации позволит контролировать нахождение человека в опасной зоне, детектировать его действия и предупреждать в случаях нахождения в зонах опасных для жизни человека. Также не маловажным фактором является цена. Исходя из этого интерес представляют алгоритмы, использующие уже имеющуюся инфраструктуру. К таким технологиям можно отнести Wi-Fi, а точнее информацию о состоянии канала связи (CSI), получаемую от Wi-Fi маршрутизатора с помощью инструмента Atheros CSI Tool[1]. При добавлении визуализации в алгоритмы локализации можно использовать Wi-Fi- маршрутизаторы вместо камер видеонаблюдения, не нарушая его конфиденциальность. Исходя из этого, можно сделать вывод, что разработка системы детектирования вторжений без нарушения факта конфиденциальности на основе алгоритмов позиционирования человека по радиосигналам является актуальной научно-технической задачей.

Целью данной работы является разработать подсистему обработки визуальной информации для обучения интеллектуального модуля позиционирования. Для достижения данной цели необходимо:

- 1) Провести анализ данных, необходимых для исследования.
- 2) Разработать лабораторный стенд.
- 3) Разработать алгоритмы получения данных для обучения интеллектуального модуля.
- 4) Разработать нейронную сеть.
- 5) Провести исследования.

Был разработан лабораторный стенд, состоящий из 2 маршрутизаторов, видеокамеры и трёх точек, на которых производились замеры. В результате проведения эксперимента было собрано 237 пакетов на первой точке измерений, 297 пакетов во второй точке, 278 пакетов в третьей точке. Каждый пакет содержит в себе 56 измерений. Каждое измерение содержит в себе 9 значений фаз и амплитуд. Для обработки данных была выбрана свёрточная нейронная сеть. Разработана нейронная сеть, представленная на рисунке 1. На вход нейронная сеть получает отдельно значения фаз и значения амплитуд на выходе нейронная сеть выдаёт изображение размером 64x64 пикселя.



Рис. 1 - Модель нейронной сети

При использовании данной нейронной сети были получены результаты, представленные на рисунке 2.

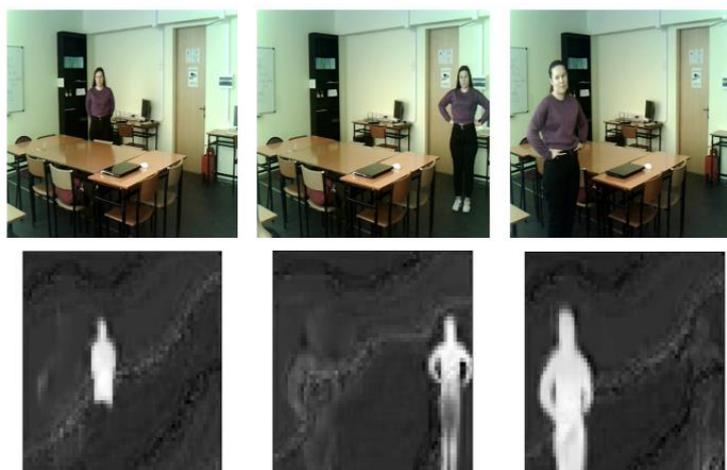


Рис. 2 - Результат обучения нейронной сети

Для эксперимента с маленьким количеством пакетов, полученный результат показывает, что данный способ детектирования человека в помещении с визуализацией имеет место быть.

Данная работа выполнена при финансовой поддержке гранта Российского научного фонда, проект № 24-21-00360

Литература

1. Yaxiong Xie, Zhenjiang Li, and Mo Li. 2015. Precise Power Delay Profiling with Commodity WiFi. In Proceedings of the 21st Annual International Conference on Mobile Computing and Networking (MobiCom '15). ACM, New York, NY, USA, 53-64. DOI: <http://dx.doi.org/10.1145/2789168.2790124>

Киселева В.А.,
Научный руководитель: к. т. н., доц. Рыжкова М.Н.
Муромский институт (филиал) федерального государственного образовательного
учреждения высшего образования «Владимирский государственный университет
имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром,
Владимирская обл., ул. Орловская, 23
vladislavasavcenko@gmail.com

Функциональная модель интеллектуального модуля системы раннего предупреждения об ошибках на производстве

Хранилище данных – класс систем в ИТ, в которых данные разной природы (логистика, производство и другое) с точки зрения бизнес-процессов собираются из многих источников для построения различных аналитик. Одна из задач хранилища – это обеспечение качества данных. Информация загружается из систем-источников, в которых могут быть ошибки, наличие которых неважно для производственного процесса, но при построении аналитики важна корректность и размеченность данных. Производственных процессов большое количество, каждый из которых знать невозможно, но нужно масштабно оценивать качество данных. Здесь стоит воспользоваться математическим прогнозированием, на основании которого можно будет делать выводы о качестве данных.

Математически прогнозировать ту или иную величину, например объем выручки или объем производства, следует на основании исторических периодов, которые уже были выверены, в качестве данных которых есть уверенность, вычислять прогноз на следующий период. Это позволит сравнить факт с теорией, и в случае отклонения заранее узнать о наличии потенциальных ошибок.

Следовательно, необходимо разработать систему, которая позволит узнать об ошибке в процессе загрузки данных до составления аналитики по ним. Сложность в том, что исторический ряд короткий, в основном величины характеризуются месяцем, а данные старше трёх лет нерелевантны, так как экономика нестабильна.

Целью данного исследования является разработка функциональной модели для обобщения работы интеллектуального модуля.

Для реализации функциональной модели необходимо последовательно разработать:

- 1) модель «чёрный ящик» для определения вида входных и выходных параметров;
- 2) модель состава для определения основных блоков обработки данных;
- 3) структурную модель для определения перемещения данных в блоках;
- 4) функциональную модель для определения работы отдельных блоков системы.

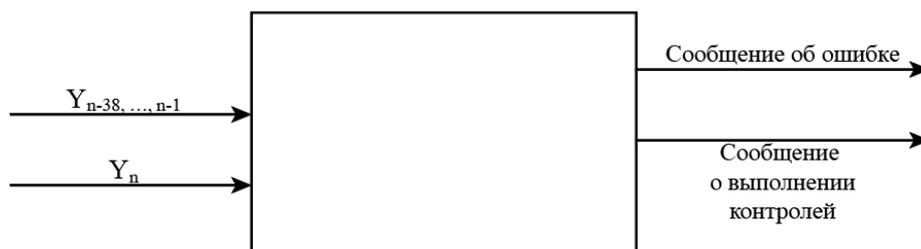


Рис. 1 – Модель «Чёрный ящик»

В начале на вход системе подаётся таблица экспериментальных данных, которая содержит ключевые показатели за 36 месяцев, исключая последний, влияющие на конечный результат отчетности, для вычисления прогнозного значения. После для сравнения факта с теорией в систему поступают значения по показателям за последний месяц. Выходными данными системы

являются: сообщение об ошибке в случае непопадания прогнозного значения в заданный интервал, сообщение о выполнении контролей по сверке данных.

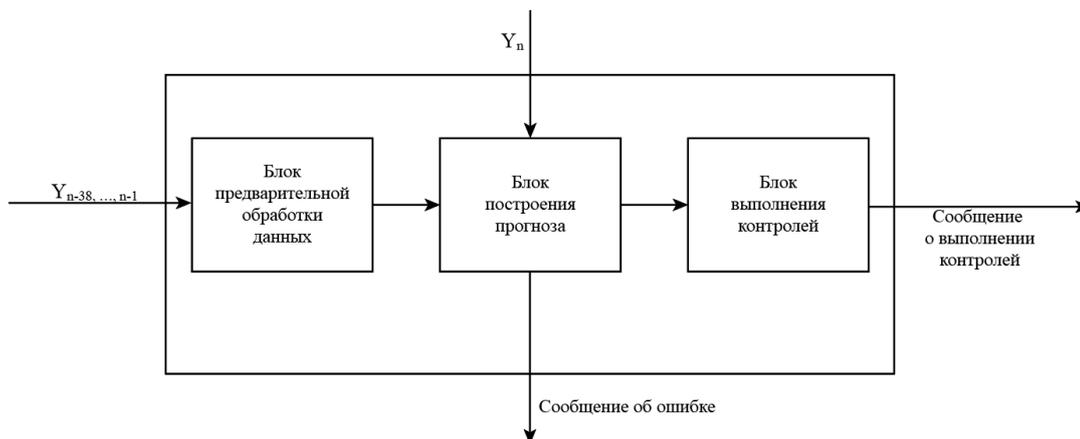


Рис. 2 – Модель состава

На рис. 2 представлены основные блоки обработки экспериментальных данных. Блок предварительной обработки данных отвечает за подготовку выборки для прогнозирования, а именно выполняет поиск и замену выбросов во временном ряду при помощи фильтра Хэмплера. Блок построения прогноза отвечает за прогнозирование текущих значений и сверку плана с фактом. Блок выполнения контролей выполняет проверки полученных данных консолидированной отчетности и уведомляет пользователей о наличии ошибок.

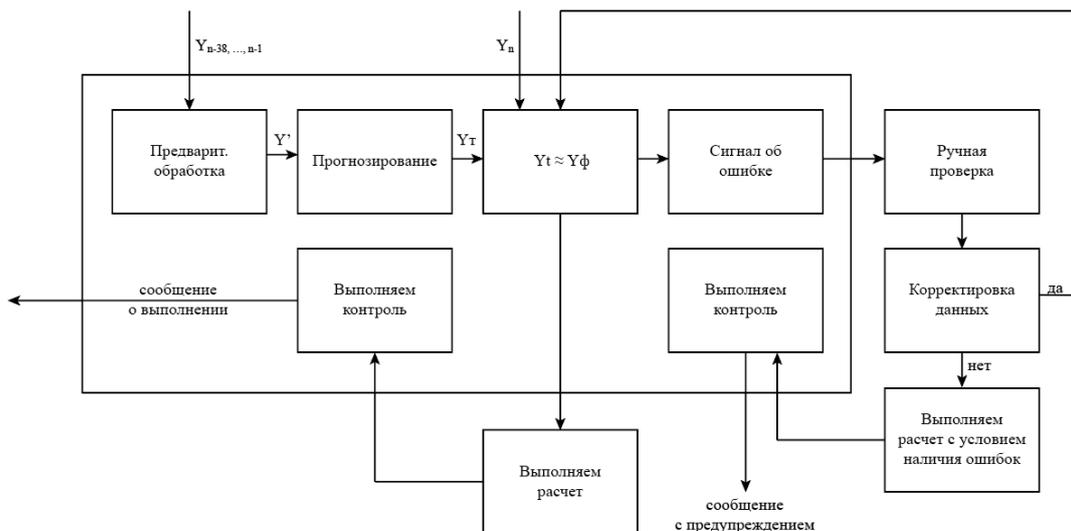


Рис. 3 – Структурная модель

На рис. 3 основное внимание уделено перемещению данных между блоками, а также показано откуда выводится выходная информация.

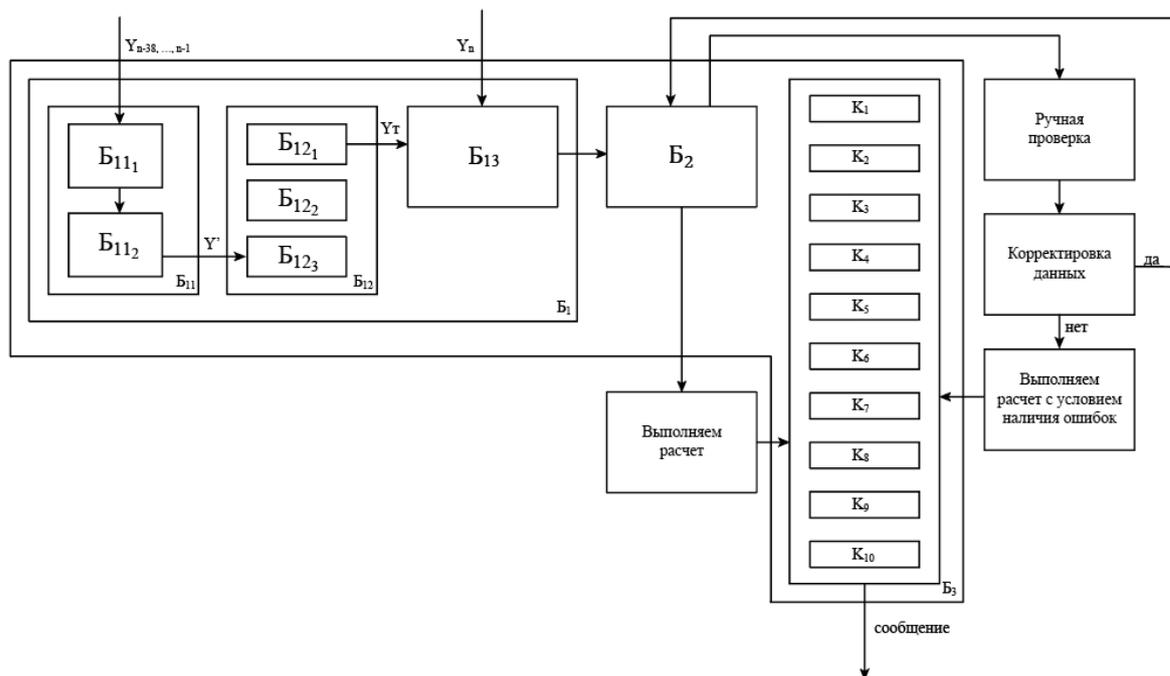


Рис. 4 – Функциональная модель

В ходе исследования был выполнен ряд поставленных задач, которые обеспечили разработку функциональной модели, описывающей последовательность работы системы и перемещение данных в ней. Перспективой дальнейшего исследования является реализация интеллектуального модуля.

Литература

1. Киселева, В. А. Метод линейной регрессии для интеллектуального модуля системы раннего предупреждения ошибок на производстве / В. А. Киселева [Текст] // Международная научно-техническая конференция молодых ученых БГТУ им. В.Г. Шухова, посвященная 170-летию со дня рождения В.Г. Шухова . — Белгород:Белгородский государственный технологический университет (БГТУ) им. В.Г. Шухова, 2023. — С. 198-202.
2. Киселева, В. А., Рыжкова, М. Н. Обзор методов анализа малой выборки / В. А. Киселева, М. Н. Рыжкова [Текст] // XV Всероссийские научные Зворыкинские чтения 2023. — Муром:Муромский институт (филиал) федерального государственного бюджетного образовательного учреждения высшего профессионального образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых», 2023. — С. 483-484.
3. Киселева, В. А. Применение фильтра Хэмплия при прогнозировании временных рядов / В. А. Киселева. — Текст : непосредственный // Международная молодежная научная конференция «XXVI ТУПОЛЕВСКИЕ ЧТЕНИЯ (школа молодых ученых)», посвященная 100-летию со дня основания гражданской авиации России. — Казань : ИП Сагиев А.Р., 2023. — С. 3120-3123.

Крёкина С.А.

Научный руководитель: к. т. н., доц. Рыжкова М.Н.

Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»

602264, г. Муром, Владимирская обл., ул. Орловская, 23

E-mail: skrekina@bk.ru

Грамотность в искусственном интеллекте

Ученые склонны думать, что искусственный интеллект (ИИ) сам по себе не страшен и, как любая технология от банальной столовой ложки до суперкомпьютера, будет обладать таким эффектом на жизнь человека, каким он сам определит. Но у тех, кто занимается внедрением ИИ в сферу образования возникают вопросы: как ИИ влияет на подрастающее поколение. Наиболее быстро на сегодняшний день развиваются возможности генеративных нейронных сетей, которые реализованы в виде чат-ботов, например, чат GPT.

Возможности чата GPT практически не ограничены в сфере генерации ответов на поисковые запросы. Одним из возможных использований ChatGPT в образовании и науке, это онлайн-обучение. Его можно использовать для предоставления пользователям информационной поддержки и руководства образовательным процессом. Взаимодействуя с ChatGPT, пользователи могут получать немедленную обратную связь по своим заданиям и вступать в диалог, адаптированный к их индивидуальным потребностям и стилю обучения. По мнениям различных источников [1] ChatGPT позволяет создавать персонализированные учебные планы и программы на основе потребностей и уровня знаний каждого учащегося, различные тестовые задания для оценивания уровня знаний.

Однако, существует ряд проблем, с которыми столкнулись пользователи, в первую очередь, достоверность сведений и фактов, предоставляемых чатом, особенно по узкоспециализированным запросам, а также ограниченность его знаний, что приводит к «придумыванию» ботом новых знаний, не всегда коррелированных с реальностью. В результате появилось такое понятие как грамотность в искусственном интеллекте. Грамотностью в искусственном интеллекте называют понимание основных принципов ИИ и его применений, а также последствий, связанных с использованием этой технологии, и её ограничений, в том числе по этическим соображениям.

Для исследования возможностей чата в образовании было проведено исследование, в котором были сформулированы различные запросы, например получить от бота тест по курсу физики средней школы по теме «Направление силы Лоренца», «Учебно-методический план по физике для 10-11 класса», «Календарно-тематический план по физике для 10-11 класса».

Ответы ChatGPT на запрос «составить тест по курсу физики средней школы по теме «Направление силы Лоренца»» были проанализированы преподавателем физики, который пояснил, что формулировка вопросов является недостаточно корректной, в некоторых вопросах отсутствуют параметры, для выбора правильного ответа, либо вопрос составлен таким образом, что приведённые варианты ответа вообще не соответствуют вопросу. Так же и с другими запросами по написанию учебно-методического и календарно-тематического планов, ответы ChatGPT являются неоднозначными, неполными, сформулированы некорректно. Следовательно, прежде чем генерировать запрос, нужно хорошо обдумать и расписать корректную формулировку запроса, затем проверить ответы на правильность.

Все перечисленное позволяет сделать вывод, что использование генеративных нейросетей в качестве помощника учителя возможно, но каждое сгенерированное задание на сегодняшний день нуждается в проверке и корректировке учителем в части формулировок, а также верности приведенных ответов и решений. В целом, потенциальные возможности применения ChatGPT в образовании и науке достаточно разнообразны, используя мощный инструмент для индивидуального обучения, совместной работы, ChatGPT обладает потенциалом трансформировать подход к образованию и научным исследованиям, но ИИ не может заменить

преподавателя, ИИ следует рассматривать скорее в качестве дополнения к традиционным методам обучения.

Литература

1. Ивахненко Е.Н., Никольский В.С. ChatGPT в высшем образовании и науке: угроза или ценный ресурс? // Высшее образование в России. 2023. Т. 32. №. 4. С. 9-22.
2. Сысоев П.В., Филатов Е.М. ChatGPT в исследовательской работе студентов: запрещать или обучать? // Вестник Тамбовского университета. Серия: Гуманитарные науки. 2023. Т. 28. №. 2. С. 276-301.
3. Гаркуша Н.С., Городова Ю.С. педагогические возможности ChatGPT для развития когнитивной активности студентов // Профессиональное образование и рынок труда. 2023. Т. 11. №. 1 (52). С. 6-23.

Лесин Н.В.

Научный руководитель: к.т.н., доцент кафедры ФПМ Макаров М.В.
Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
E-mail: lesin.kolyan.klon@gmail.com

Определение геометрических параметров физических объектов среды существования мобильного робота

В рамках создания системы управления мобильным роботом была разработана системы определения геометрических параметров объекта при лидарном сканировании. Для достижения этой цели было осуществлено решение следующих задач:

1. Анализ требований к точности определения геометрических параметров объекта для обеспечения эффективного управления мобильным роботом.
2. Анализ существующих методов и технологий лидарного сканирования для определения и анализа геометрических параметров объекта.
3. Разработка математических моделей и алгоритмов для обработки данных лидарного сканирования с целью определения геометрических параметров объекта.
4. Создание программного обеспечения для реализации алгоритмов определения геометрических параметров объекта на мобильном роботе.
5. Проведение экспериментов для верификации и калибровки разработанной системы на различных типах объектов и условиях сканирования.
6. Оценка эффективности и точности разработанной системы на практике, в том числе в условиях реальной эксплуатации мобильного робота.

Актуальность данной работы порождается следующими причинами:

1. Точное определение геометрических параметров объектов, таких как расстояния, размеры и формы, является критически важным для эффективного управления мобильным роботом в различных сценариях, включая навигацию, избегание препятствий, манипуляцию объектами и другие задачи.
2. С появлением более компактных и доступных лидарных систем, их применение в мобильных робототехнических системах становится все более распространенным, что увеличивает потребность в разработке специализированных алгоритмов и систем для обработки данных лидара.
3. Развитие технологий автономного и полуавтономного управления мобильными роботами также подчеркивает важность точной и надежной системы определения геометрических параметров объектов, поскольку она является основой для принятия решений и безопасной навигации робота в окружающей среде.

В результате работы можно ожидать следующих основных выводов:

1. Разрабатываемая система позволит точно и надежно определять геометрические параметры объектов, такие как расстояния до объектов, их размеры, формы и ориентацию, на основе данных, получаемых с лидара.
2. Эффективность разрабатываемой системы подтвердится экспериментальными исследованиями, демонстрирующими высокую точность и скорость обработки данных лидара, что важно для реального применения в условиях реального мира.
3. Внедрение данной системы в управление мобильным роботом повысит его способность к автономной навигации, обнаружению и избеганию препятствий, а также выполнению различных манипуляционных задач в различных средах.

В итоге, разрабатываемая система определения геометрических параметров объекта при лидарном сканировании в рамках управления мобильным роботом представляет собой важный шаг в развитии робототехники и технологий автономного управления, обеспечивая улучшенную способность роботов взаимодействовать с окружающей средой и выполнять разнообразные задачи с высокой точностью.

Миронов М.И., Абрамова Е.С.

Научный руководитель: д-р техн. наук, доцент, заведующий кафедрой ФПМ Орлов А.А.

Муромский институт (филиал) федерального государственного бюджетного Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»

602264, г. Муром, Владимирская обл., ул. Орловская, 23

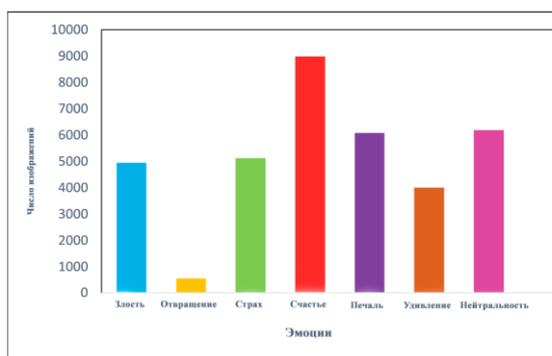
E-mail: ma.mironoff2017@yandex.ru

Распознавание эмоций на лице с помощью сверточной нейронной сети и байесовский подход для оптимизации и настройки гиперпараметров

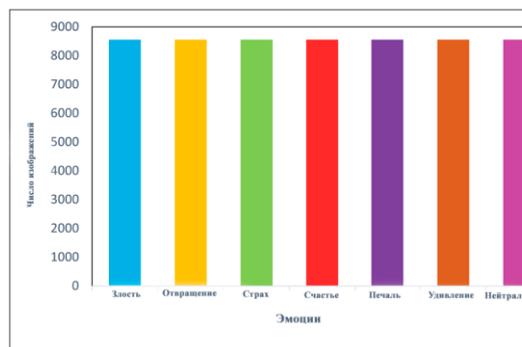
Методом, выбранным для распознавания эмоций человека, является: модель сверточной нейронной сети обучена на наборе данных FER2013. Для повышения точности модели распознавания человеческих эмоций используется обучающий набор данных соответствующего размера, также проведена байесовская оптимизация для настройки гиперпараметров.

В работе будет использован набор данных FER2013 [1]. Он состоит 32 298 изображений в градациях серого, изображающих эмоции на лице человека, которые классифицированы по семи категориям: злость, отвращение, страх, счастье, грусть, удивление и нейтральность. Следует удалить провалы, зашумленные и недостающие типы данных. Это позволит получить качественные данные. На рисунке 1 представлена диаграмма, на которой изображены 7 классов эмоций из набора данных FER2013 до балансировки данных. Ось x представляет количество классов, а ось y - количество образцов, присутствующих в наборе данных. Нейронная сеть будет эффективной, если входы в каждый слой распределены равномерно.

Модель, построенная на несбалансированных данных, может негативно повлиять на производительность, поскольку в таких случаях модель будет больше изучать класс большинства и может игнорировать или меньше изучать класс меньшинства. Чтобы решить эту проблему, набор данных был сбалансирован с помощью повторной выборки, где каждому классу было присвоено 8 500 экземпляров изображений в равной степени. Ниже на рисунке 2 показана диаграмма, на которой изображены 7 классов эмоций из набора данных FER2013 после балансировки данных.



7 классов эмоций в наборе данных FER2013.



7 классов эмоций из набора данных FER2013 после балансировки данных с 8500 образцами в каждом классе эмоций.

Поскольку нейронные сети очень чувствительны к ненормированным данным, их следует нормализовать, для получения более точных результатов. Это позволит ускорить работу нейронной сети. Следующим шагом является пакетная нормализация. Путем удаления среднего значения партии и деления на стандартное отклонение партии, пакетная нормализация нормализует выход предыдущего слоя. Масштабирование выходов позволяет быстрее обучать сеть и ускоряет процесс обучения. В качестве функции активации используется выпрямленная линейная функция активации ReLU (rectified linear activation unit).

После получения результатов первого эксперимента используем оптимальный размер обучающего набора данных вместе с методом настройки гиперпараметров [2], чтобы выяснить влияние настройки параметров на повышение точности модели для распознавания эмоций.. Размеры обучающих наборов для эксперимента: 20%, 30%, 40%, 50%, 60%, 70%, 80%, соответствующие размеры тестовых наборов - 80%, 70%, 60%, 50%, 40%, 30%, 20%. Приведены таблицы 1 и таблица 2, в которых показаны обучающий и тестовый наборы, а также полученные для них значения. Полученные значения метрик accuracy, precision, recall, и F мера, для каждого тренировочно-тестового набора.

Тренировочный набор	Тестовый набор	Тренировочная точность(accuracy)	Тестовая точность(accuracy)
20	80	66,48	66,82
30	70	71,17	72,29
40	60	71,61	73,81
50	50	72,65	74,62
60	40	72,84	74,88
70	30	73,49	75,07
80	20	74,51	75,47

Таблица 1: Точность модели на обучающих и тестовых наборах.

Тренировочный набор	Тестовый набор	Precision	Recall	F-мера
20	80	65	58	62
30	70	66	67	66
40	60	66	69	68
50	50	69	70	70
60	40	71	71	70
70	30	72	72	72
80	20	72	73	73

Таблица 2: Показатели Precision, Recall и F-мера модели на тестовых наборах.

После обучения и тестирования модели с различными размерами обучающего и тестового набора, наилучшее соотношение тренировочного и тестового наборов, при котором модель достигла максимальную точность теста 75,47%, было определено как 80% обучающего набора и 20% тестового набора. Изначально точность составляла 66,4 %, а затем наблюдался постепенный рост. За первым экспериментом последовал второй эксперимент, в котором полученный оптимальный размер обучающего набора данных был использован вместе с байесовской оптимизацией для настройки гиперпараметров с целью повышения точности для распознавания эмоций на лице человека.

Метрика	Значение %
Test_loss	78.1
Accuracy	77.21
Precision	75.00
Recall	73.00
F-мера	73.00
Loss	68.71
Test_loss	64.92

Таблица 3. Метрики оценки модели DL после байесовской оптимизации.

В таблице 3 приведены метрики оценки модели после байесовской оптимизации. Модель получила наивысшую производительность 75,47% точности при

использовании 80% обучающего набора и 20% тестового набора. После настройки гиперпараметров с помощью Байесовской оптимизации, модель улучшила производительность на 3,37%, обеспечив наилучшую точность 77,21% при обучении и 78,1% при тестировании. Показатели Precision, recall и F-мера составляют 75,00%, 73,00% и 73,00% соответственно. Улучшение производительности модели обусловлено использованием оптимального размера обучающего набора данных в сочетании с байесовской оптимизацией для настройки гиперпараметров - размера партии (batch_size), эпох (epochs) и параметров оптимизатора optimizer со значениями 32, 100 и "adam" соответственно.

Литература

1. Deschamps-Berger, T.; Lamel, L.; Devillers, L. End-to-End Speech Emotion Recognition: Challenges of Real-Life Emergency Call Centers Data Recordings. In Proceedings of the 2021 9th International Conference on Affective Computing and Intelligent Interaction (ACII), Nara, Japan, 28 September–1 October 2021.
2. S. S. Bellamkonda, "Facial Emotion Recognition by Hyper Parameter tuning of Convolutional Neural Network using Genetic Algorithm

Привезенцева К.С., Денисова П.А., Короткая А.С.

Научный руководитель: А.В. Астафьев

Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»

602264, г. Муром, Владимирская обл., ул. Орловская, 23

E-mail: ksenia.privezentseva@yandex.ru

Исследование метода главных компонент для снижения размерности данных

Сегодняшнее общество создает огромные объемы данных, которые представлены в многомерном формате, что затрудняет их анализ. Снижение размерности поможет упростить поиск зависимостей в данных, однако может привести к потере точности. Исходя из этого, тема исследования является актуальной научно-технической задачей.

Целью исследования является метод главных компонент для снижения размерности данных.

Одной из важных задач работы с данными является уменьшение их размерности с целью улучшения интерпретируемости, ускорения обучения алгоритмов машинного обучения и повышения качества принимаемых решений. Сегодня мы обсудим метод, который является одним из наиболее мощных инструментов в арсенале специалистов по обработке данных - метод главных компонент, или PCA.

PCA представляет собой статистический метод, который позволяет уменьшить размерность данных, сохраняя при этом максимальное количество полезной информации. Он использует линейную алгебру и математическую статистику, и является эффективным средством для анализа многомерных данных. Основная идея PCA заключается в поиске новых признаков, называемых главными компонентами, которые наилучшим образом коррелируют с исходными данными.

На практике, PCA может применяться для различных целей, таких как улучшение визуализации данных путем сокращения размерности, фильтрация шума из данных, повышение производительности моделей машинного обучения и многих других задач.

Принцип PCA заключается в поиске новых характеристик, называемых главными компонентами, которые имеют наибольшее соответствие с исходными данными и при этом являются ортогональными друг другу. Эти главные компоненты создают новый базис в пространстве признаков, исключая лишнюю информацию и уменьшая размерность данных.

Возьмем матрицу данных X , где каждая строка представляет наблюдение, а каждый столбец - признак. Наша задача заключается в поиске таких новых характеристик (главных компонент), которые наиболее точно отображают изменчивость данных. Главные компоненты вычисляются как собственные векторы ковариационной матрицы данных.

Ковариационная матрица позволяет нам измерить взаимосвязь между признаками. Ковариация между двумя признаками показывает, насколько они взаимосвязаны: положительная ковариация означает, что признаки изменяются в одном направлении, а отрицательная - в противоположном. Ковариационная матрица X обычно вычисляется по следующей формуле:

$$C = \frac{1}{n-1} (X - \mu)^T (X - \mu)$$

где:

- C - ковариационная матрица.

- X - матрица данных.
- μ - вектор средних значений признаков.
- n - количество наблюдений.

При использовании PCA ключевым аспектом является определение оптимального числа главных компонент. Неправильный выбор количества компонент может привести к потере информации или к излишней сложности модели. Для оценки оптимального числа компонент существуют различные методы, включая метод локтя и метод объясненной дисперсии. Эти методы помогают определить наилучшее количество компонент, которые наилучшим образом описывают изменчивость данных без излишней сложности.

Метод локтя в PCA основан на анализе доли объясненной дисперсии в зависимости от числа компонент. Строится график, где по горизонтальной оси отложено количество компонент, а по вертикальной - доля объясненной дисперсии. Форма графика напоминает изгиб локтя, и оптимальное количество компонент будет там, где уменьшение доли объясненной дисперсии замедляется.

Метод объясненной дисперсии включает выбор числа компонент таким образом, чтобы доля объясненной дисперсии достигла определенного уровня (например, 95% или 99%). Этот подход позволяет сохранить значительную часть информации при снижении размерности данных, что помогает сократить избыточность и сохранить важные характеристики данных.

Применение PCA может улучшить анализ данных, сократить вычислительные затраты и выделить наиболее информативные признаки. Однако важно помнить, что правильный выбор числа компонент и грамотная интерпретация результатов являются ключевыми факторами успешного использования PCA в проектах. Они помогают избежать потери информации, избыточной сложности модели и обеспечивают правильное понимание полученных результатов. Внимательный анализ и обоснованные решения относительно числа компонент помогут эффективно применять PCA и достигать желаемых целей в анализе данных.

Работа выполнена в рамках гранта РФФИ №24-21-00360.

Романова Е.С.

Научный руководитель: Рыжкова М.Н.

Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
e-mail: katerina_140900@mail.ru

Виртуальный практикум по дисциплине «Теория принятия решений»

В рамках дисциплины «Теория принятия решений», студенты изучают методы оптимизации, решают сложные и объемные задачи, так как в алгоритм их решения входят следующие шаги:

- нахождение производных второго порядка от функции двух переменных;
- решение системы уравнений с двумя переменными.

Кроме того, в целях формирования у студентов требуемых навыков и проведения промежуточных контрольных работ приходится решать много уравнений.

Поэтому необходимо генерировать уравнения, автоматически проверять основные этапы их решения и хранить решения, чтобы отслеживать динамику. Для такой работы был разработан виртуальный практикум (Рис. 1.), который могут самостоятельно использовать как студенты (для получения навыков решения), так и преподаватели (для контроля качества знаний).

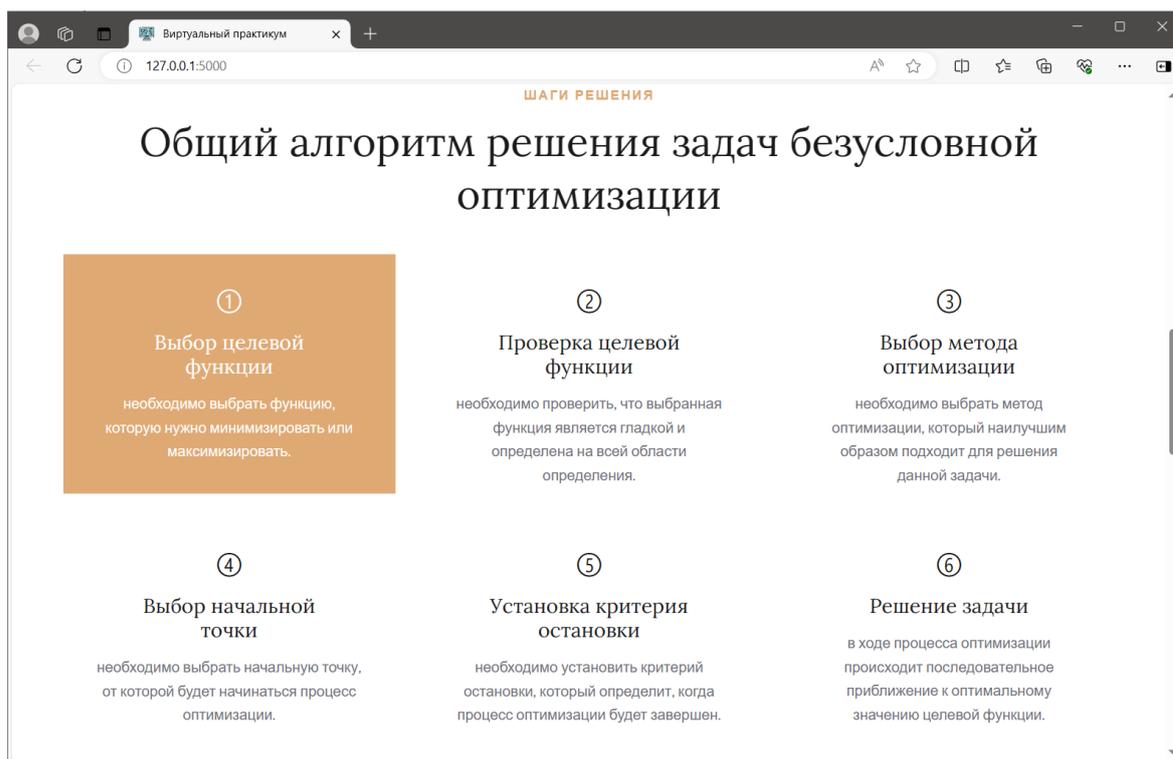


Рис. 1. – главная страница виртуального практикума

Основными задачами данного практикума являются:

- генерирование большого количества различных по форме уравнений и их поэтапное решение, в ходе которого возможно отследить промежуточные результаты, необходимые для выявления ошибок в решении;
- генерирование коэффициентов уравнения случайным образом, что исключит возможность списывания и угадывания ответов и позволит увеличить объективность оценивания полученных навыков;
- возможность добавления новых видов уравнений;

- хранение уравнений и их поэтапных решений для предоставления статистической информации: например, динамику тренировок можно будет отследить по диаграммам, которые показывают изменение времени решения уравнений.

Виртуальный практикум предоставляет преподавателям следующие возможности:

- автоматизировать процесс проверки решения задач;
- увеличить количество заданий, выдаваемых студенту в рамках занятия;
- контролировать самостоятельность работы студентов.

Виртуальный практикум предоставляет студентам следующие возможности:

- закрепить изученный материал;
- приобрести навыки решения задач по нахождению экстремума функции двух переменных;
- отследить ошибки в ходе решения;
- увидеть результаты проверки решения.

Литература

1. Ранних В. Н. Роль виртуального лабораторного практикума в улучшении когнитивных и мотивационных показателей обучения в вузе. Известия Тульского государственного университета. Гуманитарные науки. 2014:(4-2):205–210. EDN: TVWVJR

2. Романова Е. С. Тестирование онлайн-тренажера для решения задач безусловной оптимизации. Наука и образование в развитии промышленной, социальной и экономической сфер регионов России. XVI Всероссийские научные Зворыкинские чтения: сб. тез. докл. Всероссийской научной конференции. Муром, 2 февр. 2024 г.– Муром: МИ ВлГУ, 2024.– 421 с.: ил.– [Электронный ресурс]: 1 электрон. опт. диск (CD-ROM). Режим доступа: https://www.mivlgu.ru/conf/zvorykin2024/pdf/sec12_full.pdf

Семенов И.А.

Научный руководитель: к.т.н., доцент кафедры ФПМ Макаров М.В.
Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
E-mail: nauka-murom@yandex.ru

Подход к автономной навигации мобильного робота в динамической среде

Разработка системы автономной навигации для мобильных роботов является одной из ключевых задач в области робототехники. Особенно актуальной эта проблема становится в контексте создания небольших колесных платформ, предназначенных для автономного сбора данных и поиска объектов в динамически изменяющейся среде. Несмотря на значительный прогресс в этой области за последние годы, многие вопросы, связанные с обеспечением надежной и безопасной навигации таких роботов, остаются открытыми [1].

Традиционные подходы к решению задачи автономной навигации, основанные на использовании единственного типа сенсоров и упрощенных моделей окружающей среды, зачастую оказываются неэффективными в реальных условиях. Сложность геометрии местности, наличие динамических препятствий, изменчивость внешней освещенности и другие факторы могут привести к значительному снижению точности локализации робота и построения карты окружающего пространства [2]. Это, в свою очередь, негативно сказывается на возможностях целенаправленного поиска объектов и планирования оптимальных маршрутов.

Для преодоления указанных проблем необходима разработка комплексного подхода, объединяющего в себе современные методы SLAM, семантической сегментации изображений, распознавания объектов и планирования пути. Ключевым аспектом предлагаемого решения является эффективное комплексирование разнородных сенсорных данных, позволяющее компенсировать недостатки отдельных типов сенсоров и получить наиболее полное и достоверное представление об окружающей обстановке [3].

Использование алгоритмов Graph SLAM позволяет выполнять локализацию и построение карты в режиме реального времени, обеспечивая при этом высокую точность и робастность даже в условиях длительной автономной работы [4]. Применение визуальной информации в сочетании с данными лидаров и энкодеров существенно расширяет возможности системы по детектированию петель и глобальной оптимизации траектории [5]. Это позволяет минимизировать ошибки позиционирования робота, неизбежно возникающие при интегрировании локальных измерений.

Не менее важной составляющей предлагаемого подхода является использование методов глубокого обучения для семантического анализа изображений с камер робота. Современные сверточные нейронные сети способны с высокой точностью выполнять попиксельную сегментацию сцены и распознавание объектов интереса [6]. Это открывает возможности для построения насыщенных семантических карт окружающей среды, содержащих информацию не только о геометрии, но и о свойствах находящихся в ней объектов [7]. Такие карты являются ценным ресурсом для последующего целеполагания и планирования маршрута робота.

При формировании последовательности целевых точек и прокладке пути предлагается использовать комбинацию методов дискретной оптимизации и вероятностного планирования. Декомпозиция карты местности на ячейки и сведение задачи маршрутизации к поиску оптимального порядка их обхода позволяет эффективно находить решения, близкие к оптимальным по критерию минимизации затрачиваемых ресурсов [8]. В то же время, методы предиктивного планирования дают возможность строить безопасные траектории в условиях динамического окружения за счет прогнозирования возможных изменений обстановки [9].

Особое внимание в предлагаемом подходе уделяется семантической информации, поступающей от модуля анализа изображений. Учет типов распознанных объектов и их свойств позволяет строить более оптимальные и безопасные маршруты за счет адаптации целевой функции планировщика к текущему контексту [10]. Например, наличие на пути следования

робота труднопроходимых участков или областей повышенного риска может быть принято во внимание для корректировки траектории.

Отдельной проблемой является практическая реализация предложенных алгоритмов на борту мобильного робота ограниченной грузоподъемности. Современные методы SLAM, распознавания образов и планирования пути характеризуются высокой вычислительной сложностью, что накладывает существенные ограничения на производительность и энергоэффективность аппаратной платформы [11]. Для решения этой проблемы предлагается использовать комбинацию центрального процессора и специализированных ускорителей, таких как графические и тензорные процессоры, а также программируемые логические интегральные схемы [12].

Ключевым фактором, определяющим успешность практического применения разработанной системы автономной навигации, является ее всесторонняя экспериментальная проверка и оценка эффективности. Проведение испытаний на реальных полигонах и в типовых сценариях использования робота позволяет подтвердить работоспособность предложенных алгоритмов и выявить возможные недостатки. В то же время, применение реалистичных симуляторов дает возможность существенно расширить спектр тестовых сценариев и ускорить процесс отладки системы без риска повреждения дорогостоящего оборудования.

Таким образом, предлагаемый подход к построению системы автономной навигации для небольшого колесного робота, основанный на комплексировании методов SLAM, семантической сегментации, распознавания объектов и планирования пути, имеет значительный потенциал для решения задач автономного сбора данных и поиска в условиях динамической среды. Использование современных алгоритмов компьютерного зрения и машинного обучения в сочетании с эффективными стратегиями целеполагания и маршрутизации позволяет преодолеть ограничения традиционных подходов и обеспечить надежную работу робота в сложной обстановке. Дальнейшие исследования в данном направлении связаны с проведением масштабных экспериментов, оптимизацией программно-аппаратной реализации и адаптацией предложенных решений к специфическим прикладным задачам.

Литература

1. R. Siegwart, I. R. Nourbakhsh, and D. Scaramuzza, "Introduction to autonomous mobile robots," MIT press, 2011.
2. S. Thrun, W. Burgard, and D. Fox, "Probabilistic robotics," MIT press, 2005.
3. C. Cadena et al., "Past, present, and future of simultaneous localization and mapping: Toward the robust-perception age," *IEEE Transactions on Robotics*, vol. 32, no. 6, pp. 1309-1332, 2016.
4. G. Grisetti, R. Kummerle, C. Stachniss, and W. Burgard, "A tutorial on graph-based SLAM," *IEEE Intelligent Transportation Systems Magazine*, vol. 2, no. 4, pp. 31-43, 2010.
5. R. Mur-Artal and J. D. Tardos, "ORB-SLAM2: An open-source SLAM system for monocular, stereo and RGB-D cameras," *IEEE Transactions on Robotics*, vol. 33, no. 5, pp. 1255-1262, 2017.
6. A. Garcia-Garcia, S. Orts-Escolano, S. Oprea, V. Villena-Martinez, and J. Garcia-Rodriguez, "A review on deep learning techniques applied to semantic segmentation," *arXiv preprint arXiv:1704.06857*, 2017.
7. J. McCormac et al., "SemanticFusion: Dense 3D semantic mapping with convolutional neural networks," 2017 *IEEE International Conference on Robotics and Automation (ICRA)*, pp. 4628-4635, 2017.
8. T. Cabreira et al., "A survey on coverage path planning for robotics," *Computers & Operations Research*, 2019.
9. R. Ambruş et al., "Meta-learning perception and path-planning for autonomous robots," 2020 *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 4056-4063, 2020.
10. N. Pérez-Higueras et al., "Robot local navigation with learned social cost functions", 2018 *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 1-9, 2018.
11. S. Thrun et al., "Stanley: The robot that won the DARPA Grand Challenge," *Journal of Field Robotics*, vol. 23, no. 9, pp. 661-692, 2006.
12. D. Franklin, "NVIDIA Jetson TX2 delivers twice the intelligence to the edge," *NVIDIA Developer Blog*, 2017.

Титаренко Д.Ю.

Научный руководитель: к. т. н., доц. Рыжкова М.Н.

Муromский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»

602264, г. Муром, Владимирская обл., ул. Орловская, 23

E-mail: dmitrijtitar07@gmail.com

Подход к построению системы распознавания правильности выполнения физических упражнений

С ростом интереса к здоровому образу жизни становится все более актуальной необходимостью в разработке систем, способных облегчить контроль и наблюдение за физическими упражнениями. В настоящее время мы сталкиваемся с повышенным интересом к фитнесу и заботе о здоровье, и в этом контексте разработка таких систем приобретает ключевое значение.

Текущая работа основана на современных методах обработки видеопотока и использовании нейронных сетей для распознавания и контроля физических упражнений. Будет представлен инновационный подход, в основе которого лежит распознавание скелета человека, что обеспечивает более высокую точность и эффективность системы.

В отличие от существующих аналогов, разрабатываемая система предлагает интегрированный подход к распознаванию и контролю упражнений, что делает ее более надежной и функциональной.

В условиях растущего интереса к спорту и здоровому образу жизни проект приобретает особую значимость. Система может быть полезна как для людей, занимающихся фитнесом в домашних условиях, так и для профессионалов в области тренировок и спортивных соревнований. Предоставление возможности контролировать правильность выполнения упражнений поможет предотвратить травмы и повысить эффективность тренировок.

Один из подходов к построению подобной системы может быть основан на моделировании системы как информационной. Для этого требуется разработать модель типа «черный ящик», модель состава и функциональную схему системы.



Рис. 1 Модель вида «черный ящик»

Входными данными системы является X_1 - видеопоток, с изменяемым разрешением, с частотой до 240 кадров. На выходе Y_1 - рекомендации по выполнению упражнений в текстовом виде.

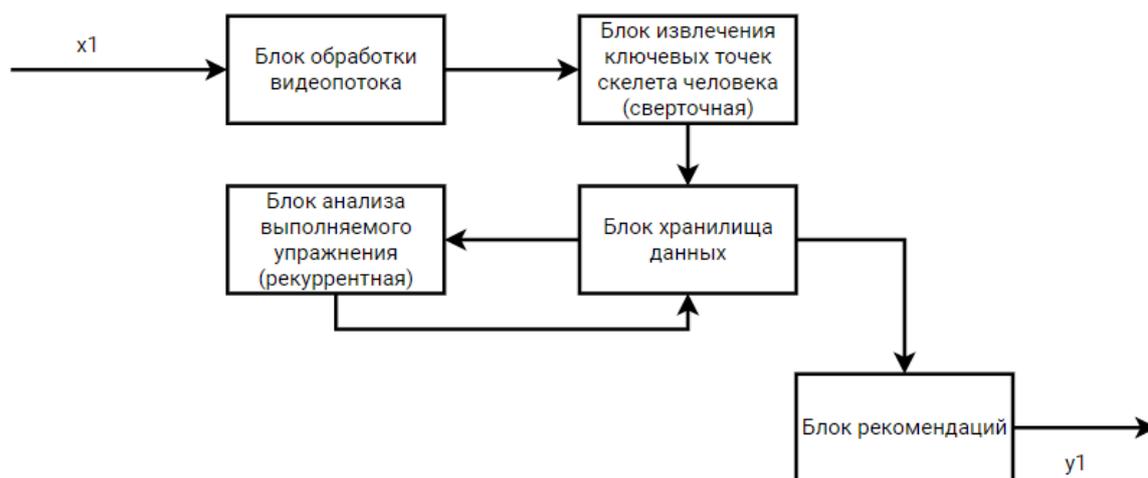


Рис. 2 – Модель типа «состав системы»

На основе модели состава системы распознавания и контроля правильности выполнения физических упражнений была разработана функциональная схема системы, которая включает в себя следующие блоки:

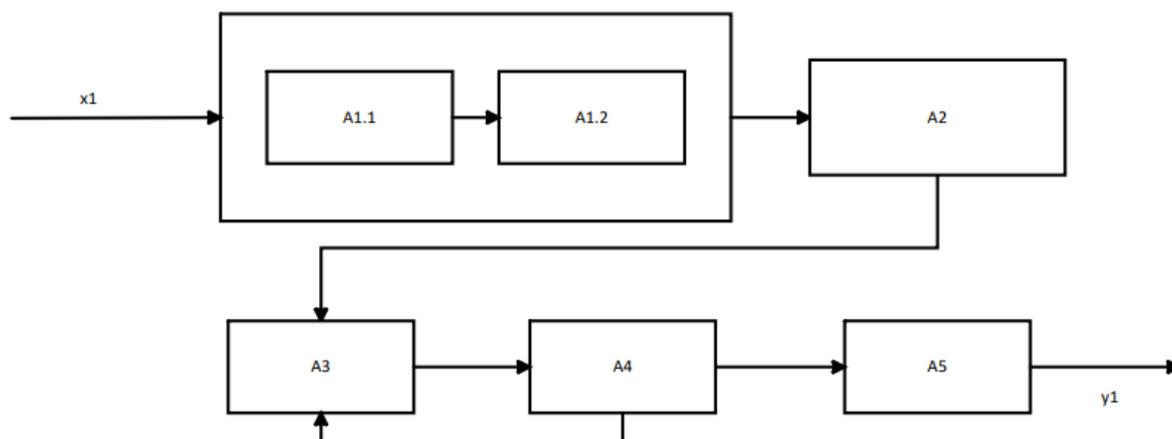


Рис. 3 – Функциональная схема системы

A1.1 – блок, выполняющий преобразование видео в формате opencv, BGR,

A1.2 – блок, выполняющий преобразование видео в массив кадров, с сохранением временной последовательности,

A2 – блок извлечения координат точек скелета человека, с использованием координаты времени и организации хранения данных в рамках одного распознавания,

A3 – блок преобразования координат скелета человека в вектор последовательности,

A4 – блок анализа последовательности на предмет выполняемого действия, ответ в виде распознанного упражнения,

A5 – блок составления рекомендаций на основе распознанного упражнения.

Разработка системы распознавания и контроля физических упражнений является важным шагом в развитии технологий, направленных на улучшение качества жизни и поддержание здоровья. Данный проект открывает новые перспективы для применения технологий в области фитнеса и спорта.

Шамилов Д. В.

Научный руководитель: д-р техн. наук, доцент, зав. кафедрой ФПМ А. А. Орлов
Муромский институт (филиал) федерального государственного образовательного
учреждения высшего образования «Владимирский государственный университет
имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
E-mail: dima.shamilof@yandex.ru

Системы мониторинга и учета эффективности показателей вуза

В современном образовательном пространстве высшее учебное заведение (ВУЗ) стоит перед задачей повышения качества образования и укрепления своей конкурентоспособности. Основным инструментом в достижении этих целей является система мониторинга и учета эффективности показателей, которая способствует обеспечению прозрачности деятельности ВУЗа и помогает в принятии обоснованных управленческих решений [2]. Перейдем к рассмотрению ключевых задач, которые ставит перед собой создание такой системы.

Основные задачи и особенности системы:

1. Автоматизация сбора данных показателей ВУЗа: система должна обеспечить автоматический сбор данных из различных источников, включая учебные планы, базы данных студентов и преподавателей, публикации и научные исследования. Это включает интеграцию с различными учебными и административными системами, а также с внешними источниками информации [1].

2. Доступ к системе с различными уровнями прав доступа: реализация многоуровневой системы авторизации, которая позволит обеспечить безопасность данных и предоставить различным группам пользователей (администрация, преподаватели) необходимый уровень доступа к системе.

3. Наследование показателей: введение иерархической структуры показателей, где высокоуровневые показатели формируются на основе агрегации данных от более низкоуровневых метрик. Такой подход позволяет лучше понимать взаимосвязи в деятельности ВУЗа и вклад отдельных подразделений в общие результаты.

4. Зависимость показателей от временной шкалы: включение функционала для анализа изменений показателей во времени, что позволяет отслеживать их динамику и сравнивать показатели за различные периоды. Система также может информировать пользователей о достижении важных этапов и сроков.

5. Прогнозирование отставания выполнения показателей: внедрение алгоритмов прогнозирования для предсказания будущих тенденций и оценки рисков отставания от запланированных целей. Использование данных из прошлого и настоящего для выявления возможных проблем в будущем поможет ВУЗу про активно вносить коррективы в образовательный процесс и управленческую деятельность. Выбор алгоритма зависит от специфики данных, наличия трендов и сезонности, а также требований к точности и скорости вычислений [3, 4]. На данный момент требуются проведения исследований для выявления более подходящего алгоритма.

Цель работы — это проектирование и разработка системы мониторинга и учета эффективности показателей вуза, обеспечивающей вышеперечисленные требования, на примере мониторинга и анализа ключевых показателей эффективности КРІ или Аналитические панели. Для реализации системы будут использоваться методы машинного обучения: случайный лес и градиентный бустинг, линейная регрессия, рекуррентные нейронные сети и LSTM.

Ширяев А.П.

Научный руководитель: к.т.н., доцент М.Н. Рыжкова

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

Разработка модуля мониторинга и прогнозирования успеваемости студентов

Целью данной работы является создания модуля для мониторинга и прогнозирования успеваемости студентов, в дальнейшем предполагается, что данный модуль будет встраиваться в систему «СКАЛА».

Под понятием «мониторинг успеваемости студентов» подразумевается отслеживания оценок студентов, т.е. пользователь системы должен иметь возможность посмотреть успеваемость студента по каждому предмету. Понятие «прогнозирование успеваемости студентов» подразумевается, что система может сказать как будет успевать студент на основе данных которые уже есть.

Требования к данной работе следующие:

- 1) Должна быть возможность просматривать успеваемость студентов;
- 2) Должна быть возможность просматривать статистику успеваемости студентов в группе;
- 3) Должна быть возможность прогноз студентов за каждый семестр.

В системе используется понятие «приведенный балл». Приведенный балл может быть от 0 до 2. Если студент по некоторому предмету имеет балл ниже 0.8, тогда такой студент считается неуспевающим.

Для прогнозирования успеваемости студентов использовался метод кластеризации, а именно к-средних. Данный метод был выбран в связи с тем, что для реализации регрессионного анализа не было достаточно данных об студентах. Все данные которые используются для анализа хранятся в базе данных «СКАЛА», поэтому сбор каких либо дополнительных данных нет возможности. И еще один из аргументов в пользу кластеризации в том, что нет четкой границы, когда студент успевающий, а когда нет, так как для кластеризации использовался средний балл студента по всем предметам по каждой контрольной неделе.

Структура таблиц в системе:

#	Имя студента	Номер зачетки	Дисциплина	Преподаватель	Кафедра	Приведенный балл
					Введите кафе	

Рис. 1 – Структура таблицы для мониторинга успевающих

Преподаватели	Дисциплина	Группа	Кол-во студентов
Введите преподавателя	Введите дисциплину	Введите группу	

Рис. 2 – Структура таблицы статистики

#	Имя Студента	Номер зачетки	Неделя № 1	Неделя № 2	Неделя № 3	Средний балл	Прогноз
	Введите имя	Введите группу					Введите прогноз

Рис. 3 – Структура таблицы предсказания

Шульпин Н.А.

Научный руководитель: к.т.н., доцент А.С. Платонова
Муromский институт (филиал) федерального государственного образовательного
учреждения высшего образования «Владимирский государственный университет
имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23

Использование информационных технологий и геймификации для обучения игре на фортепиано

В современном мире информационные технологии стремительно развиваются. Их применение возможно в различных сферах людской жизни. Например, их можно использовать для помощи человеку в изучении музыки и в обучении его игре на музыкальном инструменте, в частности, на фортепиано. С этой целью создаются специальные приложения для обучения игре на фортепиано, которые позволяют упростить процесс обучения и повысить его эффективность. Так, в статье «The effectiveness of special apps for online piano lessons» [1] было проведено исследование с целью проверки эффективности использования подобных приложений. В ходе исследования было три группы обучаемых, одна из которых обучалась только традиционными методами, а две другие дополнили свое обучение, используя по специальному приложению. По итогу, использование подобных приложений в дополнение к традиционным методам обучения игре дало более эффективный результат.

Одним из относительно новых направлений развития информационных технологий является геймификация – использование игровых элементов и игрового мышления в неигровых контекстах, введение дополнительных игровых правил в любую деятельность. Геймификация выступает средством повышения внутренней мотивации желаемого поведения пользователей или потребителей в решении стратегических задач организации. Главная задача геймификации заключается в использовании психологии игры. Желание получить удовольствие является одним из самых сильных мотивов, побуждающих человека увлеченно заниматься чем-либо [2].

Применение геймификации возможно и при обучении игре на фортепиано. В статье «Motivational effects of gamification of piano instruction and practice» [3] исследовался вопрос влияния геймификации на практику у обучающихся таких технических элементов, как гаммы, аккорды и арпеджио. На 9-недельный период было сформировано две группы, для одной из которых была разработана игра «Technique Tower» со следующими игровыми элементами: награды (баллы, достижения и уровни), аватарами и возможность делиться собственным прогрессом онлайн друг с другом (использование социального контекста). Геймификация произвела положительный эффект, так как обучаемые второй группы овладели большим количеством гамм, аккордов и арпеджио, что свидетельствует о повышении их заинтересованности и мотивации благодаря геймификации.

Таким образом, применение информационных технологий и геймификации позволяет повысить эффективность обучения игре на фортепиано, сделав данный процесс более интересным.

Литература

1. «The effectiveness of special apps for online piano lessons» Kun Lei, 18 May 2022.
2. Артамонова В. В. Развитие концепции геймификации в XXI веке //Историческая и социально-образовательная мысль. – 2018. – Т. 10. – №. 2-2. – С. 37-43.
3. Birch H. Motivational effects of gamification of piano instruction and practice. – University of Toronto (Canada), 2013