

**МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ ФЕДЕРАЦИИ**



ИНФОРМАТИКА И КИБЕРНЕТИКА

3 (37)

Донецк – 2024

УДК 004.3+004.9+004.2+51.7+519.6+519.7

**ИНФОРМАТИКА И КИБЕРНЕТИКА, № 3 (37), 2024,
Донецк, ДонНТУ.**

Специальный выпуск подготовлен по материалам, представленным на секцию «Системы искусственного интеллекта» XV Международной научно-технической конференции «Информатика, управляющие системы, математическое и компьютерное моделирование – 2024» (ИУСМКМ–2024), проведенной 29–30 мая 2024 г. в рамках X Научного форума Донецкой Народной Республики, а также результатам текущей научно-технической деятельности аспирантов, соискателей и научных работников молодежной лаборатории искусственного интеллекта ДонНТУ.

Материалы предназначены для специалистов народного хозяйства, ученых, преподавателей, аспирантов и студентов высших учебных заведений.

Редакционная коллегия

Главный редактор: Павлыш В. Н., д.т.н., проф.

Зам. глав. ред.: Мальчева Р. В., к.т.н., доц.

Ответственный секретарь: Лёвкина А. И.

Члены редакционной коллегии: Аверин Г. В., д.т.н., проф.; Аноприенко А. Я., к.т.н., проф.; Звягинцева А. В., д.т.н., доц.; Зори С. А., д.т.н., доц.; Карабчевский В. В., к.т.н., доц.; Криводубский О. А., д.т.н., доц.; Привалов М. В., к.т.н., доц.; Скобцов Ю. А., д.т.н., проф.; Сторожев С. В., д.т.н., доц.; Улитин Г. М., д.ф-м.н., проф., Федяев О. И., к.т.н., доц.; Шевцов Д. В., д.т.н., доц., Шелепов В. Ю., д.ф-м.н., проф.

Рекомендовано к печати ученым советом ФГБОУ ВО «Донецкий национальный технический университет» Министерства науки и высшего образования РФ. Протокол № 7 от 31 октября 2024 г.

Свидетельство о регистрации СМИ: серия ААА № 000145 от 20.06.2017.

Приказ МОН ДНР № 135 от 01.02.2019 о включении в Перечень рецензируемых научных изданий ВАК ДНР.

Контактный адрес редакции

РФ, ДНР, 283001, г. Донецк, ул. Артема, 58, ФГБОУ ВО «ДонНТУ»,

4-й учебный корпус, к. 36., ул. Кобозева, 17.

Тел.: +7 (856) 301-07-35, +7 (949) 334-89-11

Эл. почта: infcyb.donntu@yandex.ru

Интернет: <http://infcyb.donntu.ru>

СОДЕРЖАНИЕ

Информатика и вычислительная техника

Исследование алгоритмов машинного обучения и глубокого обучения для обнаружения опухолей в мозге человека <i>Бондаренко В. В., Рычка О. В.</i>	5
Расширение возможностей систем генерации изображений путем использования нейронных сетей <i>Мулявин Д. Е., Мальчева Р. В., Койбаш А. А.</i>	13
Алгоритмы интеллектуализации и их применение в АСУ <i>Личман А. А., Чередникова О. Ю.</i>	19
Инвестиции в искусственный интеллект: оценка экономической целесообразности и потенциальные риски <i>Похлёбин П. С., Боднар А. В., Нестеренко А.Р.</i>	25
Применение сверточных нейронных сетей для распознавания объектов на изображении <i>Волгушева А. И., Мальчева Р. В.</i>	32
Обработка текста методами естественного языка <i>Рудак Л. В., Зори С. А.</i>	39
Видеорегистрация присутствия студентов в аудитории на основе нейросетевого распознавания лиц <i>Суханов А.А., Баев Д.Э., Федяев О.И.</i>	45
Рациональные подходы к внедрению цифровых двойников в водопроводно-канализационные хозяйства <i>Штепа В. Н.</i>	51
Интеллектуальная система для оценки постурального и кинетического тремора у пациентов с диагностированной болезнью Паркинсона <i>Камбалина А. Д.</i>	58
Анализ предметных областей и программных продуктов, использующих метод конечных элементов <i>Чернышов Д. Н., Григорьев А. В.</i>	63
Особенности определения отношений в тезаурусе в области программирования <i>Коломойцева И. А., Бердюкова С.С.</i>	70
<u>Об авторах</u>	74
<u>Требования к статьям, направляемым в редакцию научного журнала «Информатика и кибернетика»</u>	76

Информатика и вычислительная техника

Исследование алгоритмов машинного обучения и глубокого обучения для обнаружения опухолей в мозге человека

В. В. Бондаренко, О. В. Рычка

E-mail: vadimbond.2000@gmail.com, olga_rychka@mail.ru

Аннотация:

Современные медицинские исследования в области визуализации сталкиваются с проблемой обнаружения опухолей головного мозга с помощью магнитно-резонансной томографии (МРТ). Опухоль головного мозга представляет собой аномальную массу ткани, в которой некоторые клетки растут и размножаются бесконтрольно, по-видимому, не регулируясь механизмами, контролирующими нормальные клетки. Существует три типа опухолей, которые обычно наблюдаются, а именно: доброкачественные, предраковые и злокачественные. Многие контролируемые и неконтролируемые алгоритмы классификации используются для определения опухоли как доброкачественной или злокачественной. Обычно более легкие наборы данных используются для классификации изображений в прикладной области, тогда как в медицинской области используются сравнительно более крупные и тяжелые наборы данных. Многие параметры, выбранные во время обучения, играют очень важную роль в измерении производительности и точности системы. Таким образом, была предпринята попытка наглядно показать, как точность алгоритма варьируется в зависимости от параметров, выбранных для обнаружения опухоли головного мозга человека по МРТ-изображению.

Введение

Обработка медицинских изображений сегодня является наиболее сложной и развивающейся областью. Сегодняшние исследования в области медицинской визуализации сталкиваются с проблемой обнаружения опухоли головного мозга с помощью магнитно-резонансной томографии (МРТ). Обычно для получения изображений мягких тканей человеческого тела специалисты используют МРТ-изображения. Его используют для анализа органов человека вместо хирургического вмешательства [1].

Слово «опухоль» является синонимом слова «неоплазма», которое образуется в результате аномального роста клеток [2]. Опухоль головного мозга представляет собой аномальную массу ткани [3], в которой некоторые клетки растут и размножаются бесконтрольно, по-видимому, не регулируются механизмами, контролирующими нормальные клетки. Рост опухоли занимает место внутри черепа и мешает нормальной деятельности мозга. Поэтому обнаружение опухоли очень важно на ранних стадиях. Для обнаружения опухолей головного мозга были разработаны различные методики [4]. Существует три типа опухолей, которые обычно наблюдаются, а именно. Доброкачественные, предраковые, злокачественные [5].

Глиома — общий термин, используемый для описания любой опухоли, возникающей из поддерживающей («клеевой») ткани головного

мозга). Эта ткань, называемая «глией», помогает удерживать нейроны на месте и обеспечивать их хорошее функционирование. Существует три типа нормальных глиальных клеток, которые могут вызывать опухоли. Астроцит будет производить астроцитомы (включая глиобластомы), олигодендроциты образуют олигодендроглиому, а эпендимомы происходят из эпендимальных клеток. Опухоли, в которых присутствует смесь этих разных клеток, называются смешанной глиомой.

Глиому также классифицируют по типу клеток, на которые она влияет. Типы глиомы:

1. астроцитома — развивается в клетках соединительной ткани, называемых астроцитами;
2. глиома ствола мозга — развивается в стволе мозга;
3. эпендимома — развивается из эпендимных клеток;
4. смешанная глиома — развивается из более чем одного типа глиомной клетки;
5. олигодендроглиома — развивается в клетках поддерживающей ткани головного мозга, называемых олигодендроцитами.
6. глиома зрительного нерва — развивается внутри или вокруг зрительного нерва.

Классификация изображений — важная задача в области компьютерного зрения. Классификация изображений означает отнесение изображений к одной из нескольких предопределенных категорий.

Классификация включает в себя датчики изображения, предварительную обработку изображения, обнаружение объектов, сегментацию объектов, извлечение признаков и классификацию объектов. Классификация изображений является важной и сложной задачей в различных областях применения, включая биомедицинскую визуализацию, биометрию, видеонаблюдение, навигация в транспортных средствах, промышленный визуальный контроль, навигация роботов и дистанционное зондирование.

Мотивация

Опухоль головного мозга, которая является одним из наиболее распространенных заболеваний головного мозга, затронула и разрушила множество жизней. По данным Международного агентства по исследованию рака (IARC), ежегодно во всем мире диагностируется опухоль головного мозга у более чем 126 000 человек, при этом уровень смертности в 2017 году превысил 97 000 человек [6]. Рак головного мозга и других нервных систем занимает 10-е место среди причин смертности мужчин и женщин. По последним оценкам, 17 760 взрослых (9 910 мужчин и 7 850 женщин) умрут от первичных раковых опухолей головного мозга и ЦНС. Несмотря на последовательные усилия по преодолению проблем опухолей головного мозга, статистика по-прежнему показывает низкую выживаемость пациентов с опухолями головного мозга. Для борьбы с этим в последнее время исследователи используют междисциплинарный подход, включающий знания в области медицины, математики и информатики, чтобы лучше понять болезнь и найти более эффективные методы лечения. Магнитно-резонансная томография (МРТ) и компьютерная томография (КТ) головного мозга являются двумя наиболее распространенными тестами, проводимыми для подтверждения наличия опухоли головного мозга и определения ее местоположения для выбранных вариантов специализированного лечения. Выбор вариантов лечения зависит от размера, типа и степени опухоли. Это также зависит от того, оказывает ли опухоль давление на жизненно важные части мозга. Распространилась ли опухоль на другие части центральной нервной системы (ЦНС) или тела и возможные побочные эффекты у пациента. Предпочтения в отношении лечения и общее состояние здоровья [10] являются важными факторами при выборе вариантов лечения.

Зачем нужна обработка изображений?

Обработка изображений — это метод выполнения некоторых операций с изображением с целью получения улучшенного изображения или извлечения из него некоторой полезной информации. Это тип обработки сигнала, при котором входными данными является изображение, а выходными данными могут быть изображение или характеристики/функции, связанные с этим изображением. В настоящее время обработка изображений является одной из быстро развивающихся технологий. Это также формирует основную область исследований в инженерных и компьютерных дисциплинах.

Почему необходима МРТ для биомедицинской визуализации?

Обработка биомедицинских изображений по своей концепции аналогична обработке биомедицинских сигналов в нескольких измерениях. Он включает в себя анализ, улучшение и отображение изображений, полученных с помощью рентгеновских лучей, ультразвука, МРТ, ядерной медицины и технологий оптической визуализации.

Магнитно-резонансная томография (МРТ) [12] является важным методом визуализации, используемым при обнаружении опухолей головного мозга. Опухоль головного мозга — одно из самых опасных заболеваний, встречающихся среди человека. МРТ головного мозга играет очень важную роль для рентгенологов в диагностике и лечении пациентов с опухолями головного мозга. Изучение медицинского изображения рентгенологом — трудоемкий процесс, а точность зависит от его опыта. Таким образом, компьютерные системы становятся очень необходимыми, поскольку они преодолевают эти ограничения. Доступно несколько автоматизированных методов, но автоматизировать этот процесс очень сложно из-за различного внешнего вида опухоли у разных пациентов.

Большинство опухолей развиваются из поддерживающих клеток головного мозга, известных как глиальные клетки. Они могут быть названы по типу клеток, из которых они состоят, или по части мозга, где они обнаружены, например, глиома ствола мозга. Более половины всех первичных опухолей головного мозга представляют собой глиомы. Насколько серьезна глиома, зависит от ее степени. Глиомы классифицируются по тому, являются ли они низкой степени злокачественности (I или II) — медленно или относительно медленно растущими, или высокой степени злокачественности (III или IV) — злокачественными, с быстрым ростом и

распространением в нормальную ткань головного мозга.

Связанные работы

В зависимости от метода визуализации и того, какой диагноз рассматривается, обработка и анализ изображений могут использоваться для определения параметров, которые определяют эффективность алгоритмов классификации опухоли по ее степеням. В этой статье проведен подробный обзор методов и наборов данных, используемых для классификации опухолей, и полученная точность была зафиксирована, как показано ниже.

Вице-президент GladisPushpa Rathi и др. [1] предложили инновационный способ

извлечения и выбора признаков. Этот метод фокусируется на использовании множества форм, текстуры и многих других особенностей опухоли, таких как белое вещество, серое вещество, спинномозговая жидкость, аномальные и нормальные области.

Используемые методы: В этом методе автор использовал анализ главных компонент (PCA) и линейный дискриминантный анализ (LDA), а также машины опорных векторов (SVM).

Сравнение линейных и нелинейных методов выполняется SVM. PCA и LDA используются для уменьшения размеров. Архитектура предлагаемой нами работы следующая (рис. 1).

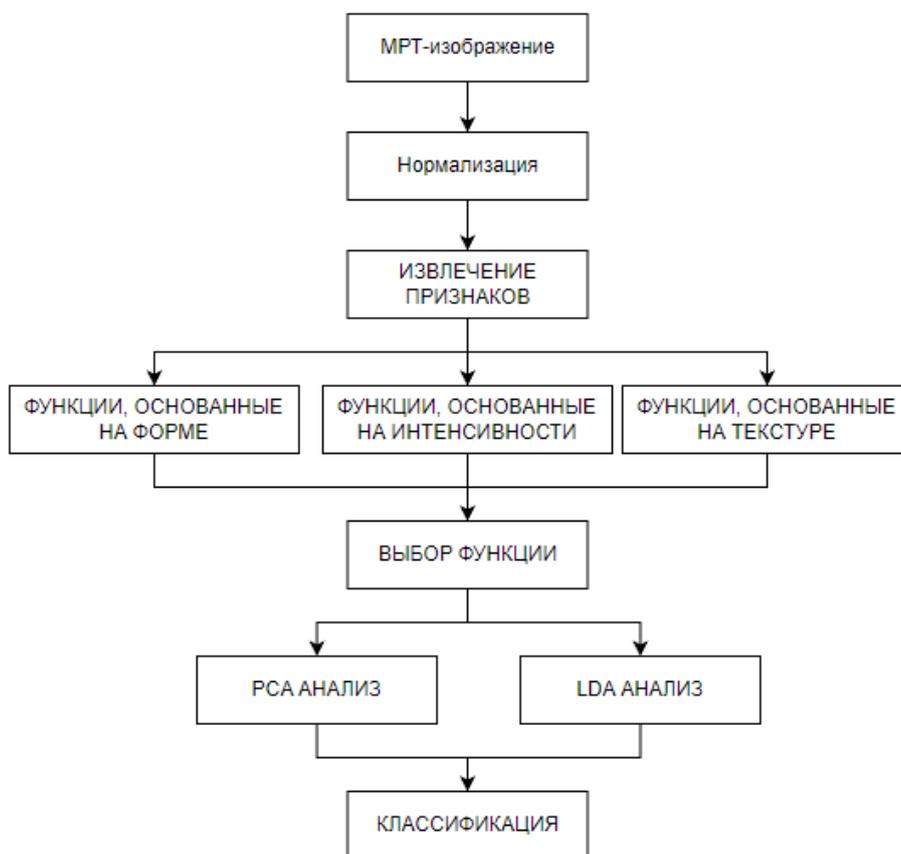


Рисунок 1 - Предложенная архитектура [1]

Изображения взяты у разных пациентов с глиомой. 24 ломтика в аксиальной плоскости толщиной 5 мм в каждом объеме. МРТ выполняли на устройствах 3Т Siemens. Набор данных изображений МРТ создается, как показано ниже (нормализация выполняется в диапазоне 0–255). Нормализация выполняется путем преобразования изображений в уровни серого 0–1 и извлечения признаков.

Здесь извлечение признаков выполняется на основе формы, интенсивности и текстуры. Характеристики формы – круглая форма,

регулярность, площадь. Характеристики интенсивности – среднее значение данных, стандартное отклонение искажения и т. д. Характеристики – контрастность, информационная мера, однородность, атрибуты кластера, такие как оттенки, сумма стандартного отклонения. Выбор характеристик осуществляется там, где извлекаются изображения с наименьшими размерами, а остальные отбрасываются. Это делается для того, чтобы данные обрабатывались алгоритмами плавно.

Прямой выбор начинается без переменных и итеративно добавляет одну за другой, что приводит к наименьшему количеству ошибок. Мы используем простой критерий отбора на основе рангов, который сравнивает два распределения.

Фаза классификации разделена на фазу обучения и тестирования. Эффективность обучения определяет точность классификации. Точность этого метода указана в таблице 1.

Таблица 1 – Значения характеристик различных наборов данных

Значения	T1	T2	FLAIR	Итого
Интенсивность	6	5	11	22
Форма	1	1	3	5
Текстура	8	5	20	33
Итого	10	20	30	60

Можно выбрать избыточные значения, но это не является предпочтительным. Для выбора более предпочтительного признака можно использовать метод ранжирования признаков.

Обратный отбор начинается со всех переменных и удаляет их итеративно до тех пор, пока любое другое удаление значительно не увеличит ошибку. Это делается для уменьшения избыточной подгонки. Для оптимизации производительности классификации используется рекурсивный алгоритм исключения признаков с помощью метода опорных векторов. Обратный отбор позволяет минимизировать вероятность ошибки на основе SVM.

Классификация осуществляется с помощью PCA и LDA. Неодинаковые частоты внутри класса проверяются на случайно выбранных тестовых данных. При этом методе максимально увеличиваются различия между классами и внутри класса.

Омидрейхани-Галангаш и др. [2] предложили метод сегментации опухоли головного мозга, основанный на алгоритме случайного леса. Предложенный метод применяется к части изображений, полученных с помощью магнитного резонанса головного мозга, и рассчитываются высокие показатели эффективности, такие как коэффициент подобия Дайса (DSC), а также точность алгоритма (ACC), которые составляют 98,38% и 97,65% соответственно. Полученный результат показал, что предложенная модель может обладать хорошей производительностью по сравнению с другими методами сегментации.

Для того чтобы точно определить область опухоли головного мозга, предлагается алгоритм разделения данных МРТ головного мозга на основе когезии (CSM). CSM привлекает большое внимание, поскольку дает

более благоприятные результаты, чем другие интеграционные процессы.

После постановки диагноза были использованы методы кластеризации и определения границ для выделения точной области опухоли, и, согласно заявлению авторов, была получена точность постановки диагноза более 99%. Подход автора состоял в том, чтобы манипулировать машинным обучением и настроить инновационный алгоритм обучения, известный как случайный лес (RF), таким образом, чтобы он мог обрабатывать большие наборы данных.

Анализ производительности показал, что качественные результаты предложенной модели аналогичны результатам, полученным с помощью двух других моделей. Выбор правильных управляющих параметров для получения лучших результатов от алгоритма является сложной задачей.

В предлагаемой работе шумовой эффект значительно снижен, что увеличивает вероятность точного определения области опухоли, так что время расчета также значительно сокращается, поскольку предложенный алгоритм прост и, следовательно, выполняет вычисления с меньшей сложностью. Поэтому был предложен алгоритм оптимизации роя частиц (PSO), основанный на кластеризации и определяющий центр масс кластеров. Каждый кластер содержит образцы опухолей головного мозга, полученные с помощью МРТ в группе. Результаты трех различных измерений производительности были сопоставлены с результатами, полученными с помощью метода опорных векторов (SVM) и методов адаптивного повышения (AdaBoost). В связи с этим, после представления математического моделирования концепции RF, автор предложил рабочий процесс для реализации процесса сегментации опухолей по данным МРТ.

Линачато и др. [3] предложили различные методы машинного обучения, такие как K-ближайших соседей, машинный вектор поддержки, дерево, ансамбль, линейный дискриминант и логистическая регрессия, которые были использованы для разработки модели прогнозирования для классификации. Было использовано множество методов выделения признаков, таких как статистическая и интенсивностная текстура, объем и местоположение, двухмерный глубокий объект и распределение по гистограммам. К признакам первого порядка относятся корреляция, энергия, Стандартное отклонение, гладкость, Энтропия, среднееквадратичное значение, контраст, однородность, момент обратной разницы и среднее значение. Наилучшая точность прогнозирования, основанная на

классификации, достигается за счет использования функций глубокого обучения, выделенных предварительно обученной сверточной нейронной сетью и прошедших обучение с помощью линейного дискриминанта.

Глиома считается агрессивным типом опухоли головного мозга, общая выживаемость не превышает двух лет и составляет 74,6% от всех злокачественных опухолей. В выборке были указаны возраст пациента, МРТ-снимки головного мозга и общее время выживания в днях. Набор данных был помечен в соответствии с коэффициентом выживаемости, т.е. краткосрочно выжившие (менее 6 месяцев), среднесрочно выжившие (от 10 до 15 месяцев) и долгосрочно выжившие (более 15 месяцев).

Рассмотренный набор данных уже был разделен на две группы: глиома более высокой степени злокачественности и глиома более низкой степени злокачественности, и были представлены четыре последовательности методов МРТ.

Был использован набор данных "Мультимодальная сегментация опухолей головного мозга 2017", содержащий 163 образца. Автор получил точность в 68,5%.

Мухаммед Тало и др. [4] предложили модель ResNet34 на основе CNN. Для обучения модели автор использовал методы глубокого обучения, такие как увеличение объема данных, определение оптимальной скорости обучения и тонкая настройка.

Предложенная модель позволила провести 5-кратную классификацию, и автор утверждает, что полученная точность составила 100%, когда для классификации использовался набор данных, состоящий из 613 МРТ-изображений. Такие аномалии, как болезнь Альцгеймера, инсульт, болезнь Паркинсона и аутизм, были классифицированы ResNet34.

Вот ранее обученная модель, которая научилась решать аналогичную задачу классификации. Архитектура ResNet34 основана на базе данных ImageNet, которая содержит более миллиона изображений, относящихся к 1000 категориям. В таблице 2 показаны результаты.

Таблица 2 – Подробные сведения о модели ResNet34

Тип слоя	Входная форма	Выходная форма	Параметры
ResNet34	3,128,128	64,64,64	9408

Автор предполагает, что архитектура ResNet34 работает быстрее по сравнению с другими предварительно обученными моделями, такими как VGG и inception. Архитектура ResNet34 очень проста в использовании в различных наборах данных по

сравнению с другими предварительно обученными моделями, такими как inception и VGG.

Хеба Мохсен (Heba Mohsen) и др. [5] предложили классификатор глубоких нейронных сетей, который является одной из архитектур DL для классификации на четыре различных класса. Опухоль головного мозга обычно возникает, когда наблюдается аномальное или неконтролируемое деление клеток головного мозга. Опухоли головного мозга бывают двух типов, а именно злокачественные и доброкачественные. Доброкачественные опухоли не распространяются, в то время как злокачественные опухоли являются злокачественными, поскольку они очень быстро растут с неопределенными границами.

Автор применил концепцию глубокого обучения для классификации опухолей головного мозга с использованием магнитно-резонансных изображений головного мозга и оценки эффективности. Основная цель предлагаемого метода - провести различие между нормальным мозгом и мозгом, пораженным опухолями разных типов. Следующий метод использует набор признаков, выделенных с помощью дискретного вейвлет-преобразования (DWT), для обучения классификатора DNN для классификации опухолей головного мозга. Из различных архитектур глубокого обучения автор предпочел использовать сверточные нейронные сети (CNN), которые могут выполнять множество видов сложных операций с использованием сверточных фильтров. После выделения признаков на полученном векторе признаков выполняется этап классификации с использованием глубокой нейронной сети.

Был рассмотрен набор данных из 66 МРТ головного мозга. Классификация выполнена с помощью DNN, содержащего структуру из 7 скрытых слоев. Автор утверждает, что получил точность 96,97%.

Автор утверждает, что хорошие результаты, которые были получены с помощью DWT, в будущем могут быть использованы в сверточной нейронной сети.

Анхель Круз-Роа и другие [6] предложили подход трансферного обучения для классификации изображений.

При обучении с переносом данных набор данных, содержащий изображения, которые необходимо классифицировать, не используется как таковой. Вместо этого мы используем предварительно обученные модели, которые используются либо как обычные объекты, либо как стратегия инициализации веса для нейронной сети, которая переобучается для другой задачи. AlexNet, Visual Geometry Group

(VGG) и Over feat - самые популярные предварительно обученные модели CNN, которые находятся в открытом доступе и победили в конкурсе ImageNet challenge, который проводится ежегодно, начиная с 2012 года. Набор данных ImageNet содержит миллионы аннотированных изображений, которые распределены по более чем тысяче различных категорий. Медуллобластома - это разновидность злокачественных опухолей головного мозга, она составляет около 25 процентов всех опухолей головного мозга, наблюдаемых у детей. В зависимости от подтипа медуллобластомы, т.е. анапластической или неанапластической, прогнозируемое течение опухоли, как правило, различается, анапластическая опухоль обычно сохраняется дольше.

Это инструмент поддержки принятия решений патологоанатомами, помогающий отличить анапластическую опухоль от неанапластической. Подход, которого придерживается автор, заключается в сравнении двух различных моделей CNN - VGG-CNN и Abc-CNN, которые ранее были обучены работе с двумя различными областями, а именно с естественными и гистопатологическими изображениями. VGG-CNN - это модель CNN, обученная классифицировать естественные изображения по 1000 категориям. Этот CNN содержит около 138 миллионов параметров, распределенных по 16 слоям, из которых 13 слоев являются слоями сверточного объединения, 2 - полностью связанными слоями

и 1 - слоем классификации softmax. IBCa-CNN - это модель CNN, обученная классифицировать гистопатологические изображения между инвазивным и неинвазивным раком молочной железы. IBCa-CNN имеет 3 слоя: один слой сверточного объединения, один полностью связанный слой и один слой классификации softmax. Автор утверждает, что обученная модель VGG-CNN не смогла классифицировать гистопатологические изображения медуллобластомы, тогда как в обученной модели IBCa-CNN средняя точность классификации составила 89,8% при стандартном отклонении 5,6 %.

Методология

В предлагаемой работе будет предпринята попытка разработать полностью автоматизированный инструмент компьютерной диагностики, который будет включать в себя различные методы обработки изображений, чтобы дать точную оценку характеристик опухоли головного мозга, а затем классифицировать их на основе непараметрических параметров с использованием машинного обучения, а также сравнить их с подходом глубокого обучения, определив идеальные гиперпараметры, которые отвечают за классификацию опухоли как доброкачественной или злокачественной, с использованием современных методов.

Общая методология классификации опухолей показана на рис. 2.



Рисунок 2 - Общая методология классификации опухолей

Признаки могут быть извлечены, как это предлагается с помощью некоторых методов, таких как прямой выбор и обратный выбор. Кроме того, некоторые функции, извлеченные с использованием методов машинного и глубокого обучения, можно сравнить с методами трансферного обучения, которые не имеют заранее определенного набора данных для определения типа подхода, который будет использоваться для получения функций.

Выводы

Различные авторы предлагали разные методы извлечения признаков в зависимости от

используемого метода обучения. В этой статье особое внимание уделяется новейшим машинам анализа тенденций и алгоритмам глубокого обучения, позволяющим классифицировать опухоли как доброкачественные или злокачественные. Различные люди получили значительные результаты и точность, полученную только на фиксированных наборах данных. В основном работа, проделанная до сих пор, заключалась в использовании различных алгоритмов машинного обучения только для данных разных размеров и стандартных наборов данных. Таким образом, эту работу можно изучить, используя подход трансферного обучения, и можно провести подробный

сравнительный анализ наборов данных различных размеров, наблюдать за поведением алгоритма и фиксировать их точность.

Таким образом, в предлагаемой работе должна быть предпринята попытка выбрать правильный алгоритм на основе размера набора данных для точной диагностики степени присутствующей опухоли путем применения методов глубокого обучения, оптимально выбирая правильные гиперпараметры, используемые для классификации образца на доброкачественный или доброкачественный. злокачественный.

Однако существуют возможности для проведения исследований по устранению пробелов, выявленных в ходе детального обследования. Подробный сравнительный анализ различных алгоритмов машинного обучения можно провести на конкретном наборе данных для классификации изображений. Также должна быть предпринята попытка масштабировать размер набора данных и применить алгоритм для проверки того, работает ли алгоритм так, как прогнозируется, это считается критическим анализом алгоритма. Предположим, алгоритм не обеспечивает прогнозируемую точность, мы настраиваем параметры, которые привели к снижению точности – это считается оптимизацией алгоритмов.

Литература

1. Ратхи, Г. П. Классификация изображений МРТ мозга с выбором и извлечением признаков с использованием линейного дискриминантного анализа / Г. П. Ратхи, В. П. Палани // IEEE, 2019.
2. Хатами, Токтам, Хамгалам, Мохаммад, Рейхани-Галангаши, Омид, Мирзкучаки, Саттар. Подход машинного обучения к сегментации опухолей мозга с использованием адаптивного алгоритма случайного леса // IEEE, 2019.
3. Чато, Лина, Латифи, Шахрам, Чато, Лина Саид. Методы машинного обучения и глубокого обучения для прогнозирования общей выживаемости пациентов с опухолями мозга с использованием МРТ // IEEE, 2017.
4. Тало, Мухаммед, Балоглу, Улас Баран, Йилдирим, Озал, Ачарья, У Раджендра. Применение глубокого трансферного обучения для автоматической классификации аномалий мозга с использованием МРТ // IEEE, 2017.
5. Мохсен, Хеба, Эль-Дахшан, Эль-Саид А., Эль-Хорбати, Эль-Саид М., Салем, Абдель-Баде. Классификация с использованием нейронных сетей глубокого обучения для опухолей мозга // IEEE, 2017.
6. Круз-Роа, Анхель, Аревало, Джон, Джаджинс, Александр, Мадабхуши, Анант, Гонсалес, Фабио. Метод дифференциации опухолей медуллобластомы на основе сверточных нейронных сетей и трансферного обучения // IEEE, 2016.
7. Сапра, Панкадж, Сингх, Рупиндерпал, Кхурана, Шивани. Обнаружение опухоли мозга с использованием нейронной сети // Международный журнал науки и современной инженерии, IJISME, ISSN: 2319-6386, Том. 1, Вып. 9, Август 2013.
8. Госвами, С. Сучита, Бхайя, Лалит Кумар П. Обнаружение опухоли мозга с использованием нейронной сети на основе неуправляемого обучения // IEEE Международная конференция по системам связи и технологиям сетей, 2013.
9. Раджешвари, С., Шри Шармила, Т. Эффективный анализ качества изображений МРТ с использованием методов предварительной обработки // IEEE Конференция по информационным и коммуникационным технологиям, ICT 2013.
10. Джордж, Е. Бен, Карнан, М. Улучшение изображений МРТ мозга с использованием методов фильтрации // Международный журнал компьютерных наук и инженерных технологий, IJCSSET, 2012.
11. Амин, Сафаа Э., Магид, М.А. Системы диагностики опухоли мозга на основе искусственных нейронных сетей и сегментации с использованием МРТ // IEEE Международная конференция по информатике и системам, INFOS 2012.
12. Натарааян П., Кришнан Н., Кенкре Наташа Сандип, Нэнси Шрайя, Сингх Бхуванеш Пратап. Обнаружение опухолей с использованием пороговой операции в МРТ изображениях мозга // IEEE Международная конференция по вычислительному интеллекту и исследованию вычислений, 2012.
13. Бауэр Стефан, Нольте Лутц-П., Рейес Маурисио. Полностью автоматическая сегментация изображений опухолей мозга с использованием классификации методом опорных векторов в сочетании с иерархическим.
14. Джоши Дипали М., Рана Н. К., Мисра В. М. Классификация рака мозга с использованием искусственной нейронной сети // IEEE Международная конференция по электронным компьютерным технологиям, ICEST, 2010.
15. Кляйн Арно и др. Оценка 14 нелинейных алгоритмов деформации, применяемых к регистрации МРТ изображений человеческого мозга // Neuro Image IEEE Журналы и журналы, Elsevier Journal, 2009. - Том 46, вып. 3, июль, С. 786-802.

Бондаренко В.В., Рычка О.В. Исследование алгоритмов машинного обучения и глубокого обучения для обнаружения опухолей в мозге человека. Современные медицинские исследования в области визуализации сталкиваются с проблемой обнаружения опухолей головного мозга с помощью магнитно-резонансной томографии (МРТ). Опухоль головного мозга представляет собой аномальную массу ткани, в которой некоторые клетки растут и размножаются бесконтрольно, по-видимому, не регулируясь механизмами, контролирующими нормальные клетки. Существует три типа опухолей, которые обычно наблюдаются, а именно: доброкачественные, предраковые и злокачественные. Многие контролируемые и неконтролируемые алгоритмы классификации используются для определения опухоли как доброкачественной или злокачественной. Обычно более легкие наборы данных используются для классификации изображений в прикладной области, тогда как в медицинской области используются сравнительно более крупные и тяжелые наборы данных. Многие параметры, выбранные во время обучения, играют очень важную роль в измерении производительности и точности системы. Таким образом, была предпринята попытка наглядно показать, как точность алгоритма варьируется в зависимости от параметров, выбранных для обнаружения опухоли головного мозга человека по МРТ-изображению.

Ключевые слова: CNN, трансферное обучение, медицинская визуализация, глиома, классификация изображений, машинное обучение, глубокое обучение

Bondarenko V.V., Rychka O.V. Research on machine and deep learning algorithms for detecting tumors in the human brain. Modern medical imaging research faces the challenge of identifying brain tumors using magnetic resonance imaging (MRI). A brain tumor is an abnormal mass of tissue in which some cells multiply uncontrollably, apparently unregulated by the mechanisms that control normal cells. There are three types of tumors that are commonly observed, namely: benign, precancerous and malignant. Many supervised and unsupervised methods are classified to determine a tumor as benign or malignant. Generally, lighter weight datasets are used for image classification in the application domain, while heavier and heavier datasets are used in the medical domain. Many parameters selected during training play a critical role in the performance and accuracy of the systems. Thus, an attempt was made to visualize how the accuracy of the algorithm increases depending on the parameters chosen to detect the human brain in an MRI image.

Keywords: CNN, Transfer Learning, Medical Imaging, Glioma, Image Classification, Machine Learning, Deep Learning.

Статья поступила в редакцию 28.05.2024
Рекомендована к публикации профессором Федяевым О. И.

Расширение возможностей систем генерации изображений путем использования нейронных сетей

Д. Е. Мулявин, Р. В. Мальчева, А. А. Койбаш

E-mail: vertik5555@mail.ru, raisa.malchea@yandex.ru, mr.koibash@yandex.ru

Аннотация:

Статья представляет обзор основных проблем, с которыми сталкиваются исследователи и практики при генерации изображений с использованием нейронных сетей. Рассматриваются ключевые аспекты, такие как вычислительная сложность и качество сгенерированных изображений. Предлагаются потенциальные решения для данных проблем, включая оптимизацию архитектур нейронных сетей, применение методов оптимизации и использование специализированных аппаратных ускорителей. Подводятся итоги перспектив развития исследований в данной области, а также указываются направления для будущих исследований и инноваций.

Введение

Генерация изображений, особенно в реальном масштабе времени, требует значительных временных затрат. Для повышения производительности систем генерации изображения их реализуют на графических процессорах, таких как платформа CUDA [1], или разрабатывают специализированные устройства [2]. При этом существует значительный объем типовых изображений (ландшафты, городские пейзажи и др.), накопленный за более чем 60 лет существования компьютерной графики. Поэтому генерировать подобные изображения традиционными методами не всегда оправдано. Исходя из этого, авторами предпринята попытка расширения возможностей систем генерации изображений путём применения искусственного интеллекта (ИИ).

Современные достижения в области ИИ стали ключевым фактором в развитии методов генерации изображений, применяемых в различных приложениях, начиная от компьютерной графики и заканчивая медицинскими исследованиями. Не смотря на значительные технологические прорывы, встречаемые в данной области, существует ряд программных и аппаратных проблем, которые препятствуют эффективной генерации качественных изображений.

Обзор основных аспектов генерации изображений с использованием нейронных сетей

При генерации изображений с использованием нейронных сетей следует учитывать несколько ключевых аспектов [3]:

- *архитектура нейронной сети*. Выбор подходящей архитектуры сети зависит от

конкретной задачи. Например, генеративно-сопоставительные сети (GAN), автокодировщики (AE), вариационные автокодировщики (VAE) и условные генеративные модели (CGAN) имеют различные свойства и применения;

- *функция потерь (Loss Function)*. Это критерий, который определяет, насколько хорошо сгенерированные изображения соответствуют оригинальным данным. В зависимости от архитектуры сети и поставленных целей могут применяться различные функции потерь, такие как бинарная кросс-энтропия, среднеквадратичная ошибка или перцептивные потери;

- *набор данных (Dataset)*. Качество и разнообразие данных напрямую влияют на качество и разнообразие сгенерированных изображений. Необходимо выбирать или создавать набор данных, который соответствует целям генерации и содержит достаточно разнообразных примеров;

- *предобработка данных (Data Preprocessing)*. Перед обучением модели данные обычно требуют предварительной обработки, такой как нормализация, изменение размера или аугментация, чтобы улучшить процесс обучения и качество результатов;

- *тренировка модели (Model Training)*. Важно правильно настроить процесс обучения, включая выбор оптимизатора, скорости обучения, количество эпох и размер мини-пакета, чтобы достичь оптимальных результатов;

- *регуляризация и предотвращение переобучения (Regularization and Overfitting Prevention)*.

Перечень проблем, возникающих в процессе генерации изображений с использованием методов искусственного интеллекта, включает следующие аспекты:

Одной из основных программных проблем является обеспечение высокого качества и реалистичности генерируемых изображений. Эта проблема обусловлена существующими ограничениями, связанными с точностью и детализацией создаваемых изображений.

Также проблемой остается скорость и эффективность алгоритмов. Процесс генерации изображений может быть крайне ресурсоемким и требовать значительного времени. Поэтому одной из задач является оптимизация алгоритмов для повышения скорости работы и эффективного использования вычислительных ресурсов [4].

Рассмотрим аппаратные проблемы.

Ограничения вычислительных ресурсов: Генерация изображений с использованием методов искусственного интеллекта может требовать значительных вычислительных мощностей, что делает этот процесс трудоемким и затратным с точки зрения аппаратного обеспечения.

Энергопотребление: Поскольку некоторые алгоритмы генерации изображений могут быть вычислительно интенсивными, они могут потреблять большие объемы энергии, особенно при работе на портативных устройствах, что представляет проблему для продолжительного использования и мобильных приложений [5].

Анализ проблем и их решение

Рассмотрим каждую из приведенных проблем и предложим решения, составленные на основе последних исследований.

Одной из главных проблем является качество и разнообразие *обучающих данных*. Модели машинного обучения, включая генераторы изображений, зависят от данных, на которых они обучаются. Если эти данные смещены, неполны или низкого качества, это отразится на результатах. Для решения этой проблемы самым оптимальным решением можно назвать улучшение качества и разнообразия наборов данных. Необходимо значительно расширять датасеты, из которых нейросеть сможет брать основу. Эта основа должна включать в себя большое количество разнообразного материала с высокими параметрами качества. Также можно использовать технику аугментации данных для увеличения количества и разнообразия обучающих примеров [6].

Следующей проблемой является неправильный *выбор архитектуры нейронной сети*. Архитектура обучающей модели играет ключевую роль в процессе генерации изображений. Она определяет структуру и функциональные возможности модели, влияя на ее способность извлекать признаки из входных данных и создавать новые изображения. В

контексте генерации изображений, архитектура обучающей модели определяет способность модели к адаптации к различным типам данных, реализации сложных зависимостей между пикселями изображения, а также способы управления качеством и разнообразием создаваемых изображений. В качестве возможного решения можно предложить применение новых архитектур нейронных сетей, которые лучше подходят для генерации изображений, например, GAN (Generative Adversarial Networks). Генеративно-сопоставительные модели представляют собой архитектуру, в которой две нейронные сети, генератор и дискриминатор, соревнуются между собой. Генератор создает изображения, а дискриминатор пытается различать реальные изображения от сгенерированных. Такая архитектура позволяет генератору научиться создавать реалистичные изображения, обманывая дискриминатор [4].

Следующей проблемой является задача оптимизации и переобучения. Эта задача является ключевой при обучении нейронных сетей для генерации изображений. Переобучение происходит, когда модель слишком сильно адаптируется к обучающим данным и начинает выделять ненужные шумы или детали, что приводит к ухудшению обобщающей способности модели на новых данных.

Для решения проблемы переобучения и оптимизации можно использовать следующие техники:

- Регуляризация. Техники регуляризации, такие как L1 и L2 регуляризация, добавляют штраф к функции потерь модели за большие веса или сложные зависимости между параметрами модели. Это помогает предотвратить избыточную сложность модели и уменьшить вероятность переобучения.

- Использование дропаута. Дропаут - это техника регуляризации, при которой случайно выбранные узлы нейронной сети игнорируются в процессе обучения. Это помогает предотвратить слишком сильную адаптацию нейронной сети к обучающим данным и уменьшить переобучение [7].

- Ранняя остановка (Early stopping). Ранняя остановка - это метод, при котором обучение модели прекращается, когда производительность модели на валидационном наборе данных начинает ухудшаться после достижения определенного максимума. Это позволяет избежать переобучения и сохранить обобщающую способность модели.

- Использование аугментации данных. Это помогает расширить обучающий набор данных и улучшить обобщающую способность модели, уменьшая вероятность переобучения [8].

Применение данных техник регуляризации и ранней остановки во время обучения нейронных сетей для генерации изображений может значительно улучшить качество и обобщающую способность моделей, а также ускорить их работу, предотвращая их переобучение и обеспечивая более стабильный процесс обучения.

Далее следует проблема, находящаяся на аппаратном уровне – недостаток быстродействия вычислительных устройств.

Проблема ограничения вычислительной мощности при генерации изображений с помощью нейронных сетей возникает из-за требовательности таких моделей к вычислительным ресурсам. Более сложные архитектуры и большие наборы данных могут потребовать значительного объема вычислительных ресурсов, включая высокопроизводительные графические процессоры (GPU) или тензорные процессоры (TPU), для обучения.

Для решения этой проблемы можно применить несколько подходов:

• Оптимизация архитектуры модели:

Использование менее ресурсоемких архитектур моделей может значительно снизить требования к вычислительной мощности. Например, использование Lightweight GAN или MobileNet для генерации изображений может помочь уменьшить нагрузку на вычислительные ресурсы без значительной потери качества.

• Дистилляция модели: Процесс дистилляции позволяет создавать более легкие и менее ресурсоемкие модели, сохраняя при этом их эффективность. Это достигается за счет передачи знаний более сложной модели на менее ресурсоемкую.

• Прогрессивное обучение: Можно начать обучение модели с более легкой и меньшей модели, а затем постепенно увеличивать ее размер и сложность по мере накопления вычислительных ресурсов или наличия данных.

• Использование облачных вычислений: Облачные сервисы предоставляют доступ к высокопроизводительным вычислительным ресурсам по запросу, что позволяет обучать и использовать модели нейронных сетей даже при ограниченной локальной вычислительной мощности.

• Применение аппроксимации моделей: Можно использовать методы аппроксимации, такие как квантизация, сжатие или обрезка моделей, чтобы уменьшить их размер и вычислительную сложность.

• Распределенное обучение: Распределение обучения модели между несколькими вычислительными устройствами или серверами может значительно ускорить процесс обучения [9, 10].

Проблема высокого энергопотребления при генерации изображений с помощью нейронных сетей схожа с предыдущей и возникает из-за высокой вычислительной нагрузки, которую они могут представлять. Более сложные модели, такие как GAN или большие наборы данных, требуют значительных вычислительных ресурсов, что приводит к увеличению энергопотребления. Это может стать проблемой с точки зрения экологической устойчивости и затрат на вычисления.

Чтобы решить эту проблему, можно применить несколько подходов:

• Оптимизация архитектуры модели:

Использование более легких и эффективных архитектур нейронных сетей может снизить энергопотребление. Например, использование MobileNet или EfficientNet для генерации изображений может уменьшить количество вычислительных операций и, следовательно, потребление энергии.

• Использование специализированных аппаратных решений: Применение специализированных аппаратных ускорителей, таких как тензорные процессоры (TPU) или ускорители глубокого обучения, спроектированных специально для работы с нейронными сетями, может существенно снизить энергопотребление при выполнении вычислений [11].

Примером реального решения является использование специализированных аппаратных ускорителей для выполнения вычислений нейронных сетей. Например, Google применяет свои тензорные процессоры (TPU) для выполнения операций нейронных сетей с высокой энергоэффективностью. Это позволяет сократить энергопотребление при обучении и инференсе моделей [12].

Современные системы с использованием искусственного интеллекта

Говоря о таких системах, нельзя обойти стороной технологии самой передовой компании в области графики – NVIDIA. Их графические адаптеры являются на сегодняшний день самыми популярными и совершенными. Во многом это тесно связано с областью кинематографа и видеоигр, поскольку именно они являются основным двигателем прогресса в области графики. Одними из важнейших для видеоигр на сегодня является технология RTX (Ray Tracing eXtreme) в связке с Deep Learning Super Sampling (DLSS), позволяющие создать фотореалистичную графику во многих современных играх.

Технология RTX является реализацией аппаратного ускорения трассировки лучей, основанного на интеграции тензорных и RT-ядер

в архитектуру графических процессоров, начиная с NVIDIA Turing. Основное новшество RTX — добавление RT-ядер для выполнения вычислений по трассировке лучей и тензорных ядер, предназначенных для ускоренной работы алгоритмов глубокого обучения, таких как DLSS.

RT-ядра — это специальные вычислительные модули в GPU, которые обрабатывают лучи для получения изображений с высокой реалистичностью, имитируя физическое поведение света. RT-ядра выполняют три основные функции: проверку пересечений, расчет теней и отражений, и вычисление взаимодействий с поверхностями. В ходе работы RT-ядра взаимодействуют с общими ядрами CUDA, которые обеспечивают основные графические вычисления. Каждое RT-ядро способно выполнять несколько операций пересечения за цикл, что существенно ускоряет рендеринг, особенно при высоких уровнях детализации и сложности сцен [13].

Тензорные ядра оптимизированы для матричных вычислений, которые играют ключевую роль в алгоритмах машинного обучения. В рамках RTX они выполняют операции свертки и матричные умножения, что позволяет ускорить модели глубокого обучения. Тензорные ядра предоставляют ресурсы для выполнения операций с плавающей запятой низкой точности (например, float 16 и float 8), что снижает нагрузку на вычислительные блоки и повышает производительность без заметных потерь в качестве изображения [13].

RT-ядра и тензорные ядра взаимодействуют с основными CUDA-ядрами, разделяя задачи по обработке графики и алгоритмов машинного обучения. CUDA-ядра обрабатывают геометрию, растеризацию и другие графические задачи, тогда как RT-ядра занимаются трассировкой лучей, а тензорные ядра поддерживают алгоритмы ИИ для оптимизации изображения (например, DLSS). Этот многозадачный подход позволяет эффективно распределять вычислительные ресурсы и минимизировать задержки в обработке графических сцен.

DLSS — это алгоритм сверхвысокого разрешения, который использует возможности глубокого обучения для повышения качества изображения при рендеринге с низким разрешением, уменьшая нагрузку на GPU. Его основой является нейронная сеть, обученная на большом количестве кадров высокого качества, что позволяет системе предсказывать и восстанавливать детали, не находящиеся в исходном изображении. DLSS состоит из двух основных компонентов: нейронной сети и механизма «апскейлинга». Нейронная сеть работает на тензорных ядрах, обучаясь на

заранее собранных наборах данных. Этот процесс включает в себя анализ кадров с низким разрешением и их улучшение до высокого разрешения с сохранением четкости и точности. Важной особенностью DLSS является интеграция шумоподавления и адаптивного сглаживания, что улучшает качество изображения, особенно в динамических сценах. Шумоподавление снижает артефакты, возникшие при апскейлинге, а адаптивное сглаживание помогает сохранить четкость на объектах с высокой детализацией [13].

Апробация

Функция `generate_image_from_text` (рисунок 1) определяет идентификатор модели и выбирает устройство (CPU или GPU), на котором будет выполняться генерация. Затем создается объект пайплайна, загружающего модель с заданным типом данных, и выполняется генерация изображения на основе текстового запроса. Полученное изображение сохраняется в файл.

```
def generate_image_from_text(prompt,
                             output_file='generated_image.png'):
    """ Генерирует изображение на основе текстового запроса
    с использованием модели Stable Diffusion.
    Аргументы:
    prompt (str): Текстовый запрос, на основе которого будет
    сгенерировано изображение.
    output_file (str): Имя файла для сохранения
    сгенерированного изображения.
    Возвращаемые значения:
    None: Изображение сохраняется на диск.
    """
    # Определение идентификатора модели
    model_id = "CompVis/stable-diffusion-v1-4"

    # Определение доступного устройства: CUDA, MPS (для
    ROCm) или CPU
    device = torch.device("cuda" if torch.cuda.is_available() else
    "mps" if torch.backends.mps.is_available() else "cpu")

    # Выбор типа данных: float16 для GPU, float32 для CPU
    dtype = torch.float16 если device.type != "cpu" else
    torch.float32
    # Создание пайплайна генерации изображения с
    заданным типом данных
    pipeline = StableDiffusionPipeline.from_pretrained(model_id,
    torch_dtype=dtype)
    pipeline.to(device)

    # Генерация изображения на основе текстового запроса
    if device.type == "cpu":
        image = pipeline(prompt).images[0]
    else:
        with torch.autocast(device.type):
            image = pipeline(prompt).images[0]

    # Сохранение изображения в файл
    image.save(output_file)
```

Рисунок 1 – Код использования функции `generate_image_from_text`

Код автоматически определяет доступное устройство, будь то CPU, GPU с поддержкой CUDA или GPU с поддержкой ROCm, и использует его для выполнения модели. Это делает код более универсальным и удобным для работы на различных системах. На рисунке 2 приведен результат работы функции при запросе «Ландшафт с горами и рекой». Время генерации на CPU составило 5:48.



Рисунок 2 – Пример генерации рисунка по тексту

Заключение

В данной статье рассмотрены основные проблемы, с которыми сталкиваются исследователи и практики при генерации изображений с использованием нейронных сетей. Основными из них являются недостаточное качество результата на выходе, большое время для выполнения алгоритмов и обучения, а также высокая вычислительная сложность, требующая значительных ресурсов для обучения. Это создает вызовы не только с точки зрения вычислительной мощности, но и с точки зрения энергопотребления и экологической устойчивости.

Однако, несмотря на эти проблемы, исследования в области генерации изображений с использованием искусственного интеллекта продолжают активно развиваться. Перспективы дальнейшего развития включают в себя улучшение качества сгенерированных изображений, увеличение их разнообразия и реалистичности, а также сокращение требуемых ресурсов для обучения.

В будущем, исследователи могут сосредоточиться на разработке более эффективных алгоритмов и архитектур нейронных сетей, которые будут более энергоэффективными и менее требовательными к ресурсам. Также важным направлением может

стать разработка методов оптимизации, улучшающих процесс обучения. Кроме того, исследования в области использования специализированных аппаратных ускорителей и облачных вычислений могут привести к существенным улучшениям в этой области.

Направлением дальнейших исследований является разработка модифицированного алгоритма генерации сложной сцены, использующего для формирования фоновой поверхности средства ИИ и генерирующего быстроизменяющиеся изображения переднего плана традиционными методами.

Литература

1. Зори, С. А. Реалистичная визуализация трехмерных объектов и сцен с использованием технологий объемного отображения / С. А. Зори, Е. А. Башков // Известия ЮФУ. Технические науки. Тематический выпуск «Компьютерные и информационные технологии в науке, инженерии и управлении». - 2012. - № 5(130). - С. 133-137.
2. Зори, С. А. Использование средств аппаратной поддержки для повышения производительности систем 3D-пространственной визуализации / С. А. Зори, А. Я. Аноприенко, Р. В. Мальцева, О. А. Авксентьева // Информатика и кибернетика. - Донецк: ДонНТУ, 2019. - № 1 (15). - С. 5-12.
3. Хайкин С. Нейронные сети: полный курс / С. Хайкин – 2-е издание. Пер. с англ. – М.: Издательский дом «Вильямс», 2006. – 1104 с.: ил.
4. Goodfellow, Ian, et al. Generative adversarial nets // Advances in neural information processing systems, 2014.
5. Zhang, R. The unreasonable effectiveness of deep features as a perceptual metric / R. Zhang // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2018. –
6. Постолит, А. В. Основы искусственного интеллекта в примерах на Python. Самоучитель / А. В. Постолит. – 2-е изд., перераб. и доп.– СПб.: БЧВ-Петербург, 2023 – 448 с.: ил.
7. Srivastava, Nitish, et al. Dropout: a simple way to prevent neural networks from overfitting // The Journal of Machine Learning Research 15.1, 2014. P. 1929-1958.
8. Shorten, Connor, and Taghi M. Khoshgoftaar. A survey on image data augmentation for deep learning // Journal of Big Data 6.1, 2019. – P. 60.
9. Howard, Andrew G., et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications // arXiv preprint arXiv:1704.04861, 2017.
10. Wu, Yuhao, et al. Progressive Growing of GANs for Improved Quality, Stability, and Variation // arXiv preprint arXiv:1710.10196, 2017.

11. Howard, Andrew G., et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications // arXiv preprint arXiv:1704.04861, 2017.

12. Google AI Blog. Google supercharges machine learning tasks with TPU custom chip [Electronic resource] - URL:

<https://ai.googleblog.com/2016/05/announcing-tpu-tensor-processing-unit.html>)

13. EIZO Rugged Solutions and NVIDIA Turing Push the Boundaries of Rugged AI [Electronic resource] - URL: https://www.unmannedsystemstechnology.com/wp-content/uploads/2021/01/NVIDIA_TuringGPU_whitepaper2021.pdf

Мулявин Д. Е., Мальчева Р. В., Койбаш А. А. Расширение возможностей систем генерации изображений путем использования нейронных сетей. Статья представляет обзор основных проблем, с которыми сталкиваются исследователи и практики при генерации изображений с использованием нейронных сетей. Рассматриваются ключевые аспекты, такие как вычислительная сложность и качество сгенерированных изображений. Предлагаются потенциальные решения для данных проблем, включая оптимизацию архитектур нейронных сетей, применение методов оптимизации и использование специализированных аппаратных ускорителей. Подводятся итоги перспектив развития исследований в данной области, а также указываются направления для будущих исследований и инноваций.

Ключевые слова: генерация изображений, нейронные сети, архитектура нейронных сетей, проблема качества изображений, задача оптимизации вычислений, ограничение вычислительной мощности.

Mulyavin D. E., Malcheva R. V., Koibash A. A. Expanding the capabilities of image generation systems by using neural networks. The article provides an overview of the main challenges faced by researchers and practitioners in generating images using neural networks. Key aspects such as computational complexity, power consumption and quality of the generated images are discussed. The paper also suggests potential solutions to these problems, including optimization of neural network architectures, application of optimization techniques, and use of specialized hardware gas pedals. The prospects for research in this area are summarized, and directions for future research and innovation are outlined.

Keywords: image generation, neural networks, neural network architecture, image quality problem, computational optimization problem, computational power limitation.

Статья поступила в редакцию 08.06.2024
Рекомендована к публикации профессором Зори С. А.

Алгоритмы интеллектуализации и их применение в АСУ

А. А. Личман, О. Ю. Чередникова
E-mail: anton.lichman@yandex.ru

Аннотация:

Предложен алгоритм поиска наилучших решений при совершенствовании работы программной части АСУ (автоматизированных систем управления), позволяющий оптимизировать затраты ресурсов АСУ на выполнение различных задач. Анализируются проблемы оптимизации алгоритмов под конкретную задачу. Алгоритм поиска наилучших решений учитывает также затраты времени, и имеет конкретные замеренные результаты, что позволяет делать промежуточные выводы о его эффективности. Приведены результаты исследований.

Введение

С помощью мощностей нейронных сетей и прочих современных развивающихся инструментов анализа можно не только создавать новое, но и совершенствовать уже рабочее старое, что позволяет внедрить интенсивные методы развития в экстенсивные, по большей части консервативные, предприятия. Также современные и довольно значимые предприятия со стандартными АСУ способны улучшить свою работу за счет усовершенствования программной части, что является актуальной в настоящее время задачей. В этих целях будут использоваться алгоритмы

интеллектуализации программной части АСУ написанной на С#.

Целью данной статьи является рассмотрение, внедрение и анализ результатов работы алгоритмов интеллектуализации, а именно, внедрение односложных и комбинированных алгоритмов с приоритетом в скорость, или точность вычислений.

Проблемы АСУ и способы их решения

Развитие автоматизированных систем управления представляет собой экспоненциальное улучшение трех уровней (рис.1), совместно или по отдельности.

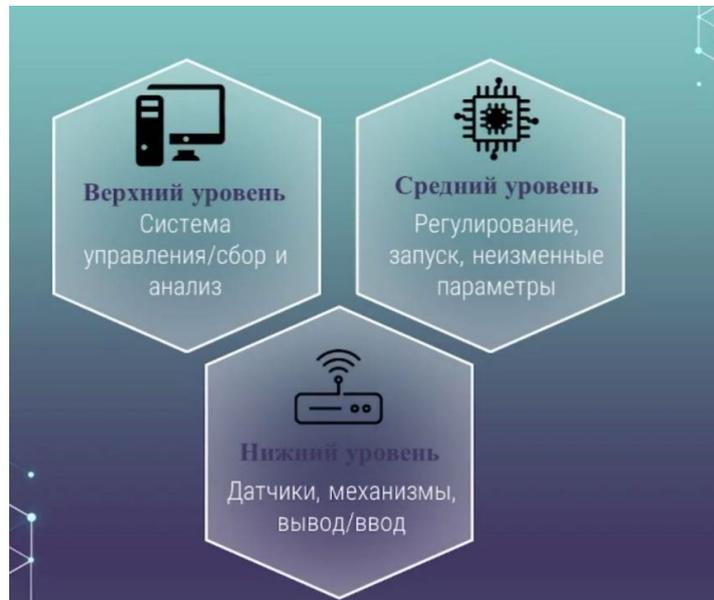


Рисунок 1 - Трехуровневая система АСУ

Нижним уровнем принято называть датчики и механизмы, систему ввода-вывода информации. Средним уровнем называют микроконтроллеры,

отвечающие за запуск и регулирование. Верхним же уровнем является непосредственно программная часть.

В современном мире АСУ постепенно замещается более новой технологией КАП (Комплексное автоматизированное производство) или по английскому CIM. В истоках данной технологии прямое продолжение АСУ, с той разницей, что АСУ является системой управления, в то же время как КАП полностью автоматизирует производство.

При должных ресурсах многие сейчас переходят на использование КАП и отдают предпочтение полной автоматизации процесса, однако в ближайшее время эта замена может быть затруднена [1].

Поскольку сейчас на рынке решения, связанные с полной автоматизацией задач

неоправданно дорогие из-за санкционной политики в отношении России, идет отказ от неоправданно дорогого повсеместного перехода на КАП, то есть полной автоматизации. Вместо этого производства и компании стараются искать дешевую альтернативу, ничуть не уступающую КАП в эффективности, а поскольку темпы улучшения датчиков и микроконтроллеров снизились, а цены на них неоправданно дорогие, приходится уповать только на улучшение программной части при помощи алгоритмов интеллектуализации (рис.2).

Развитие программной части Автоматизированных систем управления является одним из ключевых направлений современной технологической индустрии.

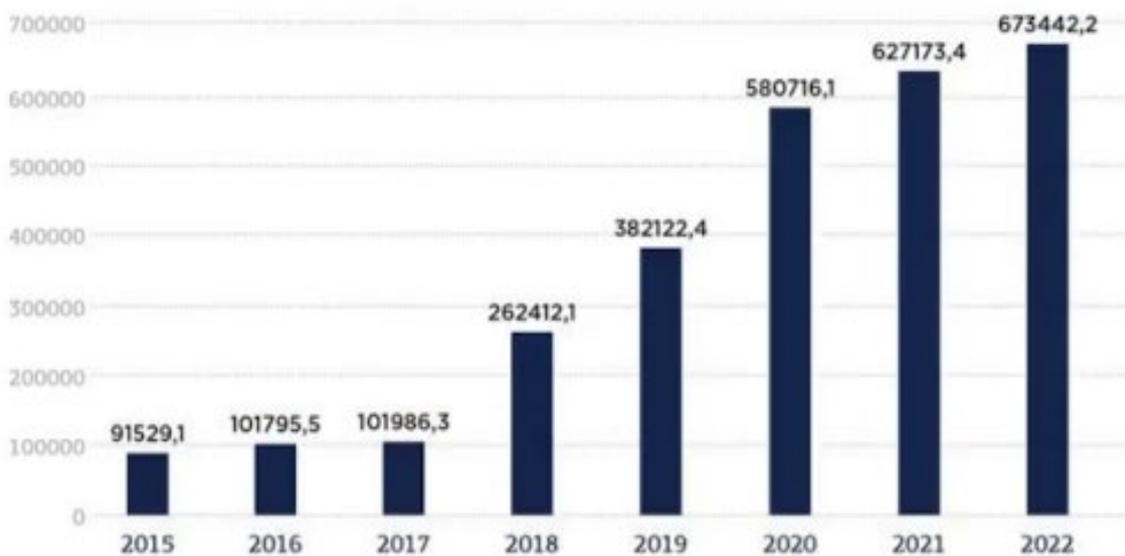


Рисунок 2 - Объем и темпы роста АСУ в России в стоимостном выражении млрд. рублей

Программное обеспечение АСУ представляет собой комплекс специализированных приложений, позволяющих автоматизировать управленческие процессы и повысить эффективность работы предприятий и организаций.

Одним из основных трендов в развитии программной части АСУ является увеличение функциональности и возможностей системы, то есть добавление новых функций к уже существующим. С появлением новых технологий, таких как искусственный интеллект, алгоритмы интеллектуализации и облачные вычисления, и интернет вещей, АСУ получают новые возможности для оптимизации процессов управления и повышения производительности. Внедрение машинного обучения и алгоритмов анализа данных позволяет системам АСУ автоматически принимать решения на основе больших объемов информации.

Кроме того, развитие программной части АСУ связано с улучшением пользовательского

опыта. Разработка интуитивно понятных и удобных интерфейсов позволяет пользователям легко взаимодействовать с системой и выполнять необходимые задачи. Постоянное обновление и совершенствование программного обеспечения позволяет АСУ быть актуальными и соответствующими современным требованиям бизнеса.

Таким образом, развитие программной части АСУ направлено на повышение производительности, эффективности и скорости управленческих процессов. Постоянное инновационное развитие в данной области является необходимым условием для успешной автоматизации управления и обеспечения конкурентоспособности организаций.

Многозадачность верхнего уровня АСУ

В АСУ для реализации верхнего уровня повсеместно применяются универсальные и многозадачные программные решения [2]. Это позволяет экономить время и ресурсы, однако

такой подход имеет ряд недостатков. Многозадачные универсальные алгоритмы могут столкнуться с рядом проблем при решении задач АСУ, в которых зачастую многие задачи выполняются одновременно. Вот некоторые из них:

1) Недостаточность ресурсов: Исполнение нескольких задач одновременно требует больших вычислительных ресурсов. Если программа использует большое количество оперативной памяти или процессорного времени, это может привести к замедлению работы компьютера и даже к его зависанию.

2) Проблемы синхронизации: при работе с несколькими задачами одновременно возникает проблема координации между ними. Если не уделить должного внимания синхронизации потоков выполнения, то это может привести к непредсказуемым результатам или даже к ошибкам в работе программы.

3) Проблемы с производительностью: Некоторые многозадачные алгоритмы могут работать менее эффективно, чем их однозадачные аналоги из-за дополнительных затрат на управление многозадачностью.

4) Распределение ресурсов: при работе с несколькими задачами одновременно важно правильно распределить ресурсы между ними. Если какая-то из задач потребляет слишком много ресурсов, это может отрицательно сказаться на выполнении других задач.

В целом многозадачные универсальные программы – это хороший инструмент, несмотря на все недостатки, однако их можно улучшить, минимизировав проблемы при помощи алгоритмов интеллектуализации – совокупности алгоритмов интеллектуального анализа данных и своеобразного узкопрофильного отладчика для исправления найденных ошибок, что дает пространство для улучшения.

Факторы, влияющие на производительность программной части АСУ

Качество АСУ описывается формулой (1).

$$J = \int_{t_0}^{t_k} G(X, U, F) dt, \quad (1)$$

где $[t_0, t_k]$ — рассматриваемый интервал времени;

$G(\dots)$ — функция, отражающая показатель качества;

X, U, F — векторы координат состояний, управлений и возмущений, соответственно.

Показатель качества G вычисляется в зависимости от типа АСУ, но в любом случае Точность и Быстродействие влияют на это значение. Точность (погрешность) измеряется по формуле (2):

$$\delta = \Delta / X_i, \quad (2)$$

где Δ - абсолютная погрешность измерений;
 X_i - истинное значение величины.

В случае, если точность не соответствует нормам, ее положено пересчитывать, изменяя значения коэффициентов формулы.

Не беря в расчет погрешность приборов, проведем эксперимент и замеряем 50 величин в исследуемой АСУ. Замеры были произведены на основе экспериментальной АСУ в сфере гидрогеологии.

Решалась задача установления плотности грунтов, а также наличия грунтовых вод. Величины, измерялись в миллиметрах водного столба.

Плотность грунтовых вод определяется по формуле (3):

$$P = p \cdot g \cdot h, \quad (3)$$

где p - давление слоя жидкости;

g – коэффициент;

h - высота слоя.

P и p - измеряемые величины, на которые нельзя повлиять программными средствами никак, кроме как констатацией их несоответствия, что обычно и так проверяется до ввода данных в программу. Остается лишь коэффициент g , который вычисляется по различным формулам с отличающейся точностью в зависимости от требований задачи.

Оценка производительности АСУ может вычисляться по формуле (4):

$$T = \sum_{i=1}^n m_i t_i, \quad (4)$$

где m - число команд;

t – время выполнения;

n - число замеров.

Однако, учитывая временные потери во время пересчета погрешности, быстродействие работы комплекса может уменьшиться [3].

Бенчмарки, как способ измерения производительности приложения

Оценка производительности программной части АСУ будет произведена при помощи бенчмарков из библиотеки BenchmarkDotNet Библиотека доступна как opensource проект на github и поддерживает широкий набор сред выполнения: .NET 5+, .NET Framework 4.6.1+, .NET Core 2.0+, Mono, NativeAOT. Добавляется через NuGET.

Для тестирования все методы должны иметь модификатор public, и к этим методам должен применяться атрибут [Benchmark]. Кроме того, сам класс, который содержит эти методы, должен иметь модификатор public. Потому

программа подсчета была модифицирована под данные условия.

Для запуска теста вызывается метод `BenchmarkRunner.Run`, который типизируется тестируемым классом:

```
BenchmarkRunner.Run<StringTest> ();
```

Для достоверности теста убираем все процессы кроме стандартных windows и запускаем программу не через Visual Studio, а через `dotnet cli`.

`BenchmarkDotNet` имеет очень много различных настроек и возможностей конфигурации, с помощью которых будет произведена первичная диагностика.

Применение пермутационной интеллектуализации

С нижних уровней программа получает данные: 50 значений, на основе которых производятся дальнейшие вычисления, и получаются 50 результатов со статистикой. Программа затрачивает определенное количество времени на их вычисление. В ходе применения пермутационной интеллектуализации мы выявим полезные пермутации и внедрим их, комбинируя показатели точности и быстродействия [4].

Пермутация – изменение заданного параметра путем корректировки не константных величин, от которых зависит данный параметр.

Программу запускаем через консоль и определяем бенчмарки: 1- точность вычисления 2- время работы.

`BenchmarkDotNet` позволяет замерять время, необходимое на весь процесс вычисления, а также результат каждого вычисления в зависимости от значения коэффициента. С помощью диагностики получаем 50 результатов прогонки (рис.3).

Погрешность не может выходить за рамки 0.05 мм.в.ст. Как видно из рис.3 для 13 и 22 измерения требуется пересчет. Пересчет производится вручную путем изменения коэффициента g .

В качестве второго эксперимента запускаем комбинированную оценку алгоритма и пытаемся его усовершенствовать: идет перебор всех возможных пермутаций (изменений) через бенчмарки (критерии), с ограничением по времени, иначе процесс может быть слишком длительным. Приоритет отдадим скорости. Проведем пермутации через бенчмарк по времени работы (рис.4).

Время работы сократилось значительно, в среднем почти на 10 секунд за счет сокращения ненужных операций, но значительно увеличилась погрешность вычислений - недопустимых значений стало 5. Как ни парадоксально пересчет данных повлек за собой значительные временные штрафы, полностью

перекрывающие 10 секунд сэкономленного времени.

№	Погрешность (мм. в. ст.)	Время сек
1	0.03	62
2	0.01	57
3	0.03	59
4	0.02	67
5	0.02	64
6	0.03	61
7	0.04	45
8	0.02	58
9	0.03	54
10	0.01	65
11	0.01	64
12	0.04	66
13	0.08	65

22	0.14	75
23	0.02	62
24	0.04	64

43	0.04	58
44	0.01	64
45	0.05	65
46	0.05	69
47	0.02	61
48	0.01	58
49	0.01	59
50	0.04	65

Рисунок 3 - Результаты первой прогонки

Приходится идти на уступки и принять как факт, что достоверно невозможно узнать идеальный вариант, однако можно найти оптимальный, не перебирая их все [5].

Остановимся на локальном поиске, где сначала определяется метрика, на основе бенчмарков сравнивается два решения и отбрасывается худшее, затем лучшее сравнивается с третьим (соседним решением) и так далее, по окончанию процесса просто выводится лучший вариант.

Данная техника оптимизации программной части АСУТП является эффективной, так как несколько строк кода могут улучшить отдельные показатели в несколько раз. В данном случае можно пренебречь так называемой концепцией «локального оптимума», так как результаты говорят сами за себя, или ждать пока появятся мощности позволяющие обработать все варианты, или все-таки верить в практический подход и улучшение (пусть гипотетически и не самое лучшее) АСУТП.

№	Погрешность (мм. в. ст.)	Время сек
1	0.05	55
2	0.04	58
3	0.04	62
4	0.13	54

13	0.08	67

22	0.14	62

43	0.28	71
44	0.04	46
45	0.05	51
46	0.06	55
47	0.05	66
48	0.03	59
49	0.02	64
50	0.04	52

Рисунок 4 - Результаты второй прогонки

Проверим предложенный вариант пермутаций с приоритетом в точность (рис.5).

№	Погрешность (мм. в. ст.)	Время сек
1	0.02	62

46	0.19	53
47	0.02	62
48	0.01	67
49	0.01	52
50	0.01	64

Рисунок 5 - Результаты третьей прогонки

Как видно из результатов, время работы немного сократилось - примерно на 2 секунды, однако точность значительно выросла. И теперь имеем всего лишь одну погрешность в 46 строке.

В процессе дальнейших прогонок результатов различных экспериментов удалось выяснить, что погрешностей действительно стало меньше, а время работы сократилось [6].

Выводы

Учитывая полученные в ходе эксперимента данные можно сделать вывод, что можно работать с АСУ при помощи алгоритмов интеллектуализации, перебирая необходимые бенчмарки в определенном порядке, что в конечном итоге приведет к появлению

«хороших» пермутаций и, как следствие, улучшенной работе программы.

Перед тем, как осуществлять проект внедрения нужно максимально формализовать его цели.

Недостатками подобного подхода является низкая актуальность подобного рода локальных улучшений без высокой плотности работы, в случае достаточно высокой степени автоматизации системы.

Такой подход помогает исключить такие затратные по времени действия как ручной пересчет погрешностей.

Однако же чем больше автоматизирована АСУ, тем менее эффективен данный метод улучшения ее работы.

Следует отметить, что использовать подобные алгоритмы можно даже в комплексном автоматизированном производстве и АСУ с высоким уровнем автоматизации, но это следует делать только при крайней необходимости максимальной оптимизации [7-10].

Литература

1. Трапезников В. А. Автоматизация проектирования систем управления // Трапезников В. А -М.: Финансы и статистика, 2017. - 208 с.
2. Фельдбаум, А. А. Вычислительные устройства в автоматических системах // А.А. Фельдбаум. - М.: Государственное издательство физико-математической литературы, 2017. - 800 с.
3. Сигорский, В. П. Многоустойчивые элементы дискретной техники // В.П. Сигорский, Л.С. Ситников, Л.Л. Утяков. - М.: Энергия, 2017. - 358 с.
4. Воронов, А. Элементы теории автоматического регулирования // А. Воронов. - М.: Воениздат, 2015. - 472 с.
5. Xianjun Ni Research of Data Mining Based on Neural Networks // World Academy of Science, Engineering and Technology. - 2008. - № 39. - P. 381-384.
6. Манжула, В.Г. Методы «мягких» вычислений для аналитической обработки информации в условиях неопределенности / В.Г. Манжула, С.А. Морозов, С.В. Федосеев // Фундаментальные исследования. - 2009. - № 4. - С. 75-76.
7. Назаров А.В., Лоскутов А.И. Нейросетевые алгоритмы прогнозирования и оптимизации систем // А.В.Назаров, А.И. Лоскутов - СПб.: Наука и Техника, 2003. - 384 с.
8. Matthew Mc-Donald WPF: Windows Presentation Foundation в .NET 4.0 with examples C# 2010 for professionals = Pro WPF in C# 2010: Windows Presentation Foundation with .NET 4.0. // Mc-Donald Matthew - М.: « Вильямс», 2011. - 1024 с.

9. Фельдбаум, А. А. Электрические системы автоматического регулирования // А.А. Фельдбаум. - М.: Государственное издательство оборонной промышленности, 2017. - 808 с.

10. Натан. А. WPF 4. Подробное руководство // А. Натан – СПб. : Символ-Плюс, 2011. – 880 с.

Личман А.А. Чередникова О.Ю. Алгоритмы интеллектуализации и их применение в АСУ. Предложен алгоритм поиска наилучших решений при совершенствовании работы программной части АСУ (автоматизированных систем управления), позволяющий оптимизировать затраты ресурсов АСУ на выполнение различных задач. Анализируются проблемы оптимизации алгоритмов под конкретную задачу. Алгоритм поиска наилучших решений учитывает также затраты времени, и имеет конкретные измеренные результаты, что позволяет делать промежуточные выводы о его эффективности. Приведены результаты исследований.

Ключевые слова: АСУ, бэнчмарки, пермутации, эффективность.

Lichman A.A. Cherednikova O.Yu. Intellectualization algorithms and their application in automated control systems. An algorithm is proposed for finding the best solutions when improving the operation of the software part of ACS (automated control systems), which allows optimizing the expenditure of ACS resources to perform various tasks. The problems of optimizing algorithms for a specific task are analyzed. The algorithm for finding the best solutions also takes into account the time spent and has specific measured results, which makes it possible to draw intermediate conclusions about its effectiveness. The results of research are done.

Keywords: ACS, benchmarks, permutations, efficiency.

Статья поступила в редакцию 10.06.2024
Рекомендована к публикации профессором Мальчевой Р. В.

Инвестиции в искусственный интеллект: оценка экономической целесообразности и потенциальные риски

П. С. Похлёбин, А. В. Боднар, А.Р. Нестеренко

E-mail: xendri@list.ru

Аннотация:

В статье выполнена оценка экономической целесообразности инвестиций в искусственный интеллект и выявлены потенциальные риски. Обсуждаются перспективы роста рынка ИИ, выгоды от его внедрения и методы оценки доходности. Анализируются технические, правовые и этические риски, а также методы их уменьшения. Надлежащая оценка выгод и рисков поможет принять обоснованные решения по инвестированию в искусственный интеллект и добиться оптимальных результатов.

Введение

Современный бизнес сталкивается с необходимостью быстрой адаптации к постоянно меняющимся условиям рынка, и в этом контексте искусственный интеллект (ИИ) становится неотъемлемым инструментом для обеспечения конкурентоспособности и эффективности [2]. Однако, решение о вложении средств в ИИ должно быть обоснованным и основано на анализе не только потенциальной экономической выгоды, но и рисков, сопутствующих этому процессу.

Экономическая целесообразность инвестиций в искусственный интеллект

Проведя анализ текущего состояния рынка искусственного интеллекта и рассмотрев его объем за последние годы, а также выделив основные сегменты, такие как машинное обучение, обработка естественного языка, компьютерное зрение и другие, мы определяем ключевые тенденции роста и прогнозы развития, основанные на данных и оценках экспертов.

Примеры успешных кейсов внедрения искусственного интеллекта:

– Финансовый сектор: Автоматизация процессов рискованного анализа и управления портфелем с помощью алгоритмов машинного обучения. Применение нейронных сетей для прогнозирования изменений на фондовом рынке и определения оптимальных стратегий инвестирования;

– Здравоохранение: Использование компьютерного зрения для диагностики рака на ранних стадиях. Разработка системы, основанной на алгоритмах глубокого обучения, для автоматического анализа медицинских изображений и выявления признаков заболевания;

– Транспортная отрасль: Создание автономных транспортных средств с возможностью распознавания дорожной обстановки и принятия решений в реальном времени. Применение искусственного интеллекта для оптимизации маршрутов доставки и управления логистикой;

– Производственная сфера: Внедрение системы предсказательного обслуживания оборудования на базе анализа больших данных. Использование ИИ для оптимизации производственных процессов, управления запасами и прогнозирования спроса на продукцию;

– Образование: Разработка индивидуализированных образовательных платформ на основе адаптивных алгоритмов обучения. Использование технологий искусственного интеллекта для персонализации учебного процесса и повышения эффективности обучения [1];

Эти примеры иллюстрируют разнообразные области применения искусственного интеллекта и его потенциал для улучшения процессов в различных сферах жизни и бизнеса.

Далее приведены примеры успешных внедрений искусственного интеллекта в различные сферы деятельности.

В финансовом секторе, компания "FinTech Solutions" столкнулась с растущим объемом данных и необходимостью быстрой и точной аналитики для принятия решений. Использование традиционных методов анализа не обеспечивало достаточной скорости и точности в условиях быстро меняющегося рынка [4]. Для решения этой проблемы, компания приняла решение использовать искусственный интеллект.

После тщательного анализа потребностей и возможностей, команда "FinTech Solutions"

решила внедрить систему автоматического рискованого анализа на базе алгоритмов машинного обучения. С помощью этой системы, компания смогла автоматизировать процесс анализа финансовых данных, идентифицировать потенциальные риски и предсказывать возможные сценарии развития рынка.

В результате внедрения искусственного интеллекта, компания "FinTech Solutions" существенно увеличила скорость и точность аналитических решений, снизила риски инвестирования и повысила свою конкурентоспособность на рынке финансовых услуг.

В медицинской клинике "MedTech Innovations" столкнулись с проблемой выявления раковых заболеваний на ранних стадиях, когда традиционные методы диагностики не всегда достаточно эффективны. Исходя из этой проблемы, команда "MedTech Innovations"

приняла решение использовать компьютерное зрение для автоматизации процесса диагностики.

С помощью алгоритмов глубокого обучения, разработанной системе удалось анализировать медицинские изображения, такие как рентгенограммы и снимки МРТ, с высокой точностью и выявлять признаки рака на ранних стадиях развития. Это позволило врачам быстрее и точнее диагностировать заболевания, увеличивая шансы на успешное лечение и выживание пациентов [3].

В результате внедрения системы компьютерного зрения, клиника "MedTech Innovations" улучшила качество медицинской помощи, сократила время на диагностику и повысила эффективность лечения раковых заболеваний.

Ниже приведена таблица 1, в которой показана тенденция востребованности искусственного интеллекта.

Таблица 1 - Динамика рынка искусственного интеллекта за 5 лет

Период	Общий объем рынка ИИ (в млрд. долларов)	Машинное обучение (в млрд. долларов)	Обработка естественного языка (в млрд. долларов)	Компьютерное зрение (в млрд. долларов)	Прочие сегменты рынка	Прогнозы развития
5 лет назад	100	30	20	15	35	Ожидалось удвоение объема рынка за следующие 5 лет
4 года назад	150	40	25	20	45	Прогнозировалось увеличение рынка на 50% к концу следующего года
3 года назад	200	50	35	25	90	Ожидалось, что рынок продолжит расти со стабильным темпом
2 года назад	250	60	45	30	115	Прогнозировалось увеличение рынка на 20% в следующем году
Год назад	300	70	55	35	140	Прогнозируется дальнейший рост рынка с сохранением высоких темпов

Методы снижения рисков при инвестировании в искусственный интеллект: обучение персонала, разработка этических стандартов, использование надежных алгоритмов и т.д.

Инвестирование в искусственный интеллект (ИИ) открывает перед компаниями и организациями множество преимуществ, способствующих их развитию и конкурентоспособности. Основные выгоды включают:

– ИИ позволяет автоматизировать рутинные и повторяющиеся задачи, освобождая сотрудников для более сложной и творческой работы. Например, в производственной сфере внедрение ИИ-систем для контроля качества продукции и предсказания поломок

оборудования значительно повышает эффективность производственных процессов;

– Использование ИИ-технологий может существенно сократить операционные расходы. В сфере обслуживания клиентов, чат-боты и виртуальные ассистенты обрабатывают запросы клиентов в автоматическом режиме, уменьшая необходимость в большом количестве сотрудников. В здравоохранении ИИ помогает оптимизировать процессы диагностики и лечения, что снижает затраты на медицинские услуги; [2]

– ИИ предоставляет возможности для анализа больших объемов данных, что позволяет компаниям лучше понимать потребности своих клиентов и разрабатывать продукты и услуги, максимально соответствующие этим потребностям. В ритейле, например, ИИ

используется для персонализации предложений и прогнозирования спроса, что способствует расширению клиентской базы и увеличению продаж;

– Алгоритмы машинного обучения и компьютерного зрения позволяют выявлять дефекты и несоответствия на ранних стадиях производства, что способствует улучшению качества конечной продукции. В финансовом секторе ИИ помогает обнаруживать мошеннические операции и предотвращать финансовые потери [1, 6];

– ИИ позволяет компаниям быстро реагировать на изменения рыночных условий и адаптироваться к ним. В условиях высокой конкурентной среды это становится важным фактором для выживания и процветания бизнеса. Например, в логистике и управлении цепочками поставок ИИ помогает оптимизировать маршруты доставки и управлять запасами в режиме реального времени, что снижает издержки и повышает оперативность [5];

– Инвестиции в ИИ стимулируют развитие новых продуктов и услуг, которые ранее были невозможны или экономически нецелесообразны. В сфере здравоохранения это может быть разработка новых методов лечения и диагностики, в образовании – создание персонализированных учебных программ, а в финансовом секторе – новые инструменты для управления инвестициями и рисками.

Возврат инвестиций (ROI) является ключевым показателем для оценки эффективности проектов по внедрению искусственного интеллекта (ИИ). ROI показывает, насколько выгодно вложение в тот или иной проект, и помогает компаниям принимать обоснованные решения о дальнейших инвестициях. Рассмотрим основные методы оценки ROI и приведем практические примеры;

Методы оценки ROI в проектах ИИ

1. Классический метод ROI

Классическая формула расчета ROI:

$$ROI = \frac{ЧП - ЗИ}{З} * 100\% , \quad (1)$$

где ЧП - чистая прибыль от инвестиций, включая все дополнительные доходы, полученные в результате внедрения ИИ;

ЗИ – затраты на инвестиции.

2. Метод окупаемости (Payback Period)

Этот метод определяет период, за который инвестиции окупятся (ПО). Он помогает оценить, насколько быстро проект начнет приносить прибыль. Формула:

$$ПО = \frac{\text{Затраты на проект}}{\text{Ежегодный доход от проекта}} \quad (2)$$

3. Метод чистой приведенной стоимости (NPV)

NPV оценивает текущее значение всех будущих денежных потоков, связанных с проектом. Положительное значение NPV указывает на прибыльность проекта. Формула:

$$NPV = \sum_{t=0}^T \frac{C * F_t}{(1+r)^t} - \text{Первоначальные инвестиции}, \quad (3)$$

где $C * F_t$ – денежный поток в период t ,

r - ставка дисконтирования,

T – продолжительность проекта.

4. Внутренняя норма доходности (IRR)

IRR — это ставка дисконтирования, при которой NPV равен нулю. Этот показатель помогает определить потенциальную доходность проекта и сравнить его с альтернативными инвестициями.

Проведем практический пример для компании "FinTech Innovations":

Компания "FinTech Innovations" внедрила систему машинного обучения для анализа кредитных рисков. Инвестиции в проект составили \$2 млн. В результате внедрения, компания снизила уровень непогашенных кредитов на 15%, что привело к ежегодной экономии в \$1 млн. Кроме того, автоматизация анализа сократила затраты на персонал на \$0.5 млн ежегодно.

чистая прибыль от проекта: \$1 млн (экономия на рисках) + \$0.5 млн (снижение затрат на персонал) = \$1.5 млн ежегодно.

Затраты на проект: \$2 млн.

$$ROI = \frac{1.5\text{млн} - 2\text{млн}}{2\text{млн}} * 100 = -25\% (1\text{й год}). \quad (4)$$

Период окупаемости:

$$ПО = \frac{2\text{млн}}{1.5\text{млн}} = 1,33 \text{ года}. \quad (5)$$

Анализ ROI является важным инструментом для оценки эффективности проектов по внедрению ИИ. Методы оценки, такие как классический ROI, период окупаемости, NPV и IRR, позволяют компаниям принимать обоснованные решения о целесообразности инвестиций. Практические примеры демонстрируют, что вложения в ИИ могут привести к значительным экономическим выгодам, улучшению производительности и сокращению затрат, несмотря на начальные высокие затраты.

Потенциальные риски инвестирования в искусственный интеллект

Инвестирование в искусственный интеллект (ИИ) сопровождается рядом потенциальных рисков, которые необходимо учитывать для успешного внедрения и

эксплуатации ИИ-систем. В этом разделе рассмотрим основные риски, факторы, влияющие на их возникновение, и методы их снижения [7].

Идентификация основных рисков

Технические риски включают недостаточную эффективность алгоритмов и технические сбои. Алгоритмы ИИ могут не всегда давать точные или надежные результаты, особенно при работе с недостаточно качественными или неполными данными. Технические сбои могут привести к значительным потерям и остановкам в бизнес-процессах (таблица 2).

Таблица 2 - Примеры технических рисков и их последствий

Технические риски	Примеры последствий
Недостаточная эффективность алгоритмов	Неправильные рекомендации, потеря доверия клиентов
Технические сбои	Остановка производственных линий, нарушение бизнес-процессов
Сложности интеграции	Задержки во внедрении, дополнительные расходы
Ограниченные возможности масштабирования	Проблемы с расширением и адаптацией системы
Обновления и поддержка	Необходимость постоянного обновления, возможные сбои

Правовые риски (таблица 3) связаны с соблюдением различных законов и нормативных актов, регулирующих сбор, обработку и хранение данных.

Таблица 3 - Примеры правовых рисков и их последствий

Этические риски	Примеры последствий
Бiais и дискриминация	Несправедливые решения, общественное возмущение
Этические дилеммы	Вопросы допустимости, необходимость разработки этических стандартов
Несправедливость решений	Социальные и правовые последствия, снижение доверия
Конфликт интересов	Подрыв корпоративной культуры, утрата общественного доверия
Проблемы приватности	Негативные последствия для пользователей, юридические проблемы

Компании должны учитывать комплаенс и регуляторные требования. Неясность в определении ответственности за решения, принятые ИИ, может привести к юридическим спорам и санкциям.

Факторы, влияющие на риски в проектах искусственного интеллекта

Не прогнозируемость данных является значительным фактором риска. Данные, используемые для обучения ИИ, могут быть неполными, неточными или содержать ошибки. Это может привести к неправильным выводам и решениям [8].

Недостаточная эффективность алгоритмов также представляет собой риск. Даже самые передовые алгоритмы могут работать неэффективно, если они обучены на некорректных данных или используются в неподходящих условиях. Это может привести к значительным финансовым потерям.

Проблемы конфиденциальности и безопасности данных становятся всё более актуальными с ростом объемов обрабатываемой информации. Необходимость защиты данных от утечек и несанкционированного доступа требует дополнительных затрат и усилий.

Сопrotивление изменениям со стороны сотрудников может затруднить внедрение новых технологий. Без надлежащего обучения и поддержки персонала внедрение ИИ может столкнуться с внутренними барьерами [9].

Методы снижения рисков при инвестировании в искусственный интеллект

Обучение персонала играет ключевую роль в снижении рисков. Компании должны инвестировать в подготовку сотрудников к работе с новыми технологиями, чтобы они могли эффективно использовать ИИ в своей деятельности.

Разработка этических стандартов и норм является важным шагом для предотвращения предвзятости и дискриминации в алгоритмах. Эти стандарты помогут компаниям разработать справедливые и прозрачные системы ИИ.

Использование надежных и проверенных алгоритмов может значительно снизить технические риски. Компании должны проводить тщательное тестирование и валидацию алгоритмов перед их внедрением.

Защита конфиденциальности и безопасности данных требует внедрения современных методов шифрования и других технологий защиты информации. Это поможет предотвратить утечки и несанкционированный доступ к данным [10].

Регулярный мониторинг и аудит систем ИИ позволяют своевременно выявлять и устранять потенциальные проблемы. Компании должны постоянно отслеживать работу своих систем ИИ и вносить необходимые коррективы.

Таблица 4 - Методы снижения рисков при инвестировании в искусственный интеллект

Методы снижения рисков	Описание
Разработка этических стандартов	Создание и внедрение этических норм для предотвращения биаса
Использование надежных алгоритмов	Проведение тщательного тестирования и валидации алгоритмов
Обучение персонала	Инвестиции в обучение и подготовку сотрудников
Защита конфиденциальности и безопасности данных	Внедрение современных методов шифрования и технологий защиты данных
Регулярный мониторинг и аудит	Постоянный контроль и аудит систем ИИ для своевременного выявления проблем

Оценка экономической целесообразности инвестиций в искусственный интеллект для ДонНТУ

Для определения экономической целесообразности инвестиций в искусственный интеллект (ИИ) для Донецкого национального технического университета (ДонНТУ) необходимо провести всесторонний анализ, включающий оценку потенциальных выгод, рисков и необходимых ресурсов. Рассмотрим ключевые аспекты, которые помогут принять обоснованное решение о целесообразности внедрения ИИ в учебное заведение.

Рассмотрим потенциальные выгоды для ДонНТУ.

1. Улучшение образовательного процесса:

– Индивидуализация обучения: Использование ИИ для создания персонализированных образовательных траекторий позволит учитывать индивидуальные особенности и потребности каждого студента, что повысит эффективность обучения;

– Автоматизация административных процессов: Внедрение ИИ для автоматизации задач, таких как планирование расписания, управление учебными материалами и обработка заявок, сократит временные затраты преподавателей и сотрудников, позволив им сосредоточиться на более важных задачах;

2. Расширение научно-исследовательских возможностей:

– Анализ больших данных: Использование ИИ для обработки и анализа больших объемов данных в различных научных исследованиях повысит качество и скорость проведения научных работ;

– Новые научные направления: Внедрение ИИ позволит развивать новые научные направления и сотрудничество с ведущими исследовательскими центрами и университетами;

3. Повышение конкурентоспособности:

– Привлечение абитуриентов: Современные технологии, такие как ИИ, могут стать привлекательным фактором для абитуриентов, желающих получать образование в инновационном учебном заведении.

– Улучшение имиджа: Внедрение ИИ способствует повышению репутации университета как передового научно-образовательного учреждения.

Потенциальные риски для ДонНТУ

1. Технические риски:

– Недостаток квалифицированных кадров: Возможные проблемы с наймом специалистов, обладающих необходимыми навыками для разработки и поддержки ИИ-систем.

– Инфраструктурные ограничения: Технические ограничения существующей инфраструктуры, которые могут потребовать значительных инвестиций для модернизации.

2. Финансовые риски:

– Высокие первоначальные затраты: Значительные инвестиции на начальном этапе для разработки и внедрения ИИ-систем.

– Неопределенность возврата инвестиций: Сложности с точной оценкой экономической эффективности внедрения ИИ и риски неполучения ожидаемого ROI.

3. Правовые и этические риски:

– Соблюдение законодательства: Необходимость соответствия законодательным нормам, регулирующим использование ИИ и обработку данных.

– Этические вопросы: Решение вопросов, связанных с этическим использованием ИИ в образовательном процессе.

Методы оценки экономической целесообразности

Для оценки экономической целесообразности инвестиций в ИИ для ДонНТУ следует применить комплексный подход, включающий следующие этапы:

1. Анализ затрат и выгод (СВА):

– Определение затрат: включает прямые и косвенные расходы, связанные с разработкой, внедрением и эксплуатацией ИИ-систем.

– Оценка выгод: Качественные и количественные выгоды, которые университет может получить от внедрения ИИ, такие как улучшение образовательных результатов,

сокращение административных затрат и повышение конкурентоспособности.

2. SWOT-анализ:

– Сильные стороны (Strengths): Текущие конкурентные преимущества университета, которые могут усилиться благодаря ИИ.

– Слабые стороны (Weaknesses): Текущие проблемы и ограничения, которые могут препятствовать успешному внедрению ИИ.

– Возможности (Opportunities): Внешние возможности для развития и роста благодаря использованию ИИ.

– Угрозы (Threats): Внешние риски и угрозы, которые могут повлиять на успешность инвестиций.

3. Примеры успешных кейсов в образовании:

– Изучение опыта других образовательных учреждений, успешно внедривших ИИ. Анализ их подходов, достигнутых результатов и извлеченных уроков поможет сформировать более обоснованное решение.

Вывод

Инвестиции в искусственный интеллект представляют значительный потенциал для увеличения эффективности бизнеса и современных образовательных учреждений. Однако, успешная реализация таких инвестиций требует всестороннего анализа экономической целесообразности и оценки потенциальных рисков.

В данной статье рассмотрены ключевые аспекты этого процесса, включая обзор рынка ИИ, примеры успешных кейсов и анализ ROI. Также выявлены потенциальные риски и предложены методы их снижения.

Надлежащая оценка выгод и рисков поможет принять обоснованные решения по инвестированию в искусственный интеллект и добиться оптимальных результатов.

Литература

1. Иванов, А. Б. Экономическая эффективность внедрения искусственного интеллекта в образовательные учреждения [Текст] / А. Б. Иванов // Вестник экономической науки. — 2020. — № 3. — С. 45-58.

2. Козлов, В. Г. Потенциальные риски инвестирования в искусственный интеллект: анализ и стратегии управления [Текст] / В. Г. Козлов // Экономика и финансы. — 2019. — Т. 15, № 2. — С. 112-125.

3. Смирнова, Е. Д. Оценка экономической целесообразности внедрения технологий

искусственного интеллекта в образовательные учреждения [Текст] / Е. Д. Смирнова // Экономические науки. — 2018. — № 5. — С. 76-89.

4. Петров, Г. М. Методы анализа доходности инвестиций в искусственный интеллект: практические аспекты [Текст] / Г. М. Петров // Финансовые исследования. — 2017. — Т. 12, № 4. — С. 98-110.

5. Кузнецова, О. Н. Прогнозирование развития рынка искусственного интеллекта: модели и методы [Текст] / О. Н. Кузнецова // Экономический анализ и прогнозирование. — 2016. — № 7. — С. 24-35.

6. Дзялошинский, И. М. Когнитивные процессы человека и искусственный интеллект в контексте цифровой цивилизации : монография / И. М. Дзялошинский. — Москва : Ай Пи Ар Медиа, 2022. — 583 с. — ISBN 978-5-4497-1596-8. — Текст : электронный // Цифровой образовательный ресурс IPR SMART : [сайт]. — URL: <https://www.iprbookshop.ru/119443.html>

7. Веревкин, А. П. Искусственный интеллект в задачах моделирования, управления, диагностики технологических процессов : монография / А. П. Веревкин, Т. М. Муртазин. — Москва, Вологда : Инфра-Инженерия, 2023. — 232 с. — ISBN 978-5-9729-1428-9. — Текст : электронный // Цифровой образовательный ресурс IPR SMART : [сайт]. — URL: <https://www.iprbookshop.ru/132995.html>

8. Пылов, П. А. Изучение искусственного интеллекта на основе принципа интенсификации обучения : монография / П. А. Пылов, Р. В. Майтак, А. В. Дягилева. — Москва, Вологда : Инфра-Инженерия, 2024. — 172 с. — ISBN 978-5-9729-1594-1. — Текст : электронный // Цифровой образовательный ресурс IPR SMART : [сайт]. — URL: <https://www.iprbookshop.ru/143203.html>

9. Потюпкин, А. Ю. Искусственный интеллект на базе информационно-системной избыточности : монография / А. Ю. Потюпкин, А. В. Чечкин. — Москва : КУРС, 2024. — 384 с. — ISBN 978-5-907064-44-7. — Текст : электронный // Цифровой образовательный ресурс IPR SMART : [сайт]. — URL: <https://www.iprbookshop.ru/144789.html>

10. Кобелев, Н. Б. Имитация как искусственный интеллект управления новым глобальным миром : монография / Н. Б. Кобелев. — Москва : КУРС, 2024. — 144 с. — ISBN 978-5-907352-83-4. — Текст : электронный // Цифровой образовательный ресурс IPR SMART : [сайт]. — URL: <https://www.iprbookshop.ru/144856.html>

Похлёбин П. С., Боднар А. В., Нестеренко А.Р. Инвестиции в искусственный интеллект: оценка экономической целесообразности и потенциальные риски. В статье выполнена оценка экономической целесообразности инвестиций в искусственный интеллект и выявлены потенциальные риски. Обсуждаются перспективы роста рынка ИИ, выгоды от его внедрения и методы оценки доходности. Анализируются технические, правовые и этические риски, а также методы их уменьшения. Надлежащая оценка выгод и рисков поможет принять обоснованные решения по инвестированию в искусственный интеллект и добиться оптимальных результатов.

Ключевые слова: искусственный интеллект, инвестиции, экономическая целесообразность, риски, ROI, оценка

Pokhlebin P. S., Bodnar A.V., Nesterenko A.R. Investments in artificial intelligence: assessment of economic feasibility and potential risks. The article evaluates the economic feasibility of investing in artificial intelligence and identifies potential risks. The prospects for the growth of the AI market, the benefits of its implementation and methods for evaluating profitability are discussed. Technical, legal and ethical risks are analyzed, as well as methods to reduce them. Proper assessment of benefits and risks will help you make informed decisions on investing in artificial intelligence and achieve optimal results.

Keywords: artificial intelligence, investments, economic feasibility, risks, ROI, evaluation

Статья поступила в редакцию 12.06.2024
Рекомендована к публикации профессором Федяевым О. И.

Применение сверточных нейронных сетей для распознавания объектов на изображении

А. И. Волгушева, Р. В. Мальчева

Email: korkoalena@yandex.ru, raisa.malcheva@yandex.ru

Аннотация:

Выполнен анализ принципов работы искусственных нейронных сетей, сферы их применения для распознавания объектов на изображении. Выбран и реализован алгоритм на основе сверточных нейронных сетей, способный с довольно высокой точностью обнаруживать на изображении выбранные классы объектов. Использование данного алгоритма для анализа видеопотоков, получаемых с касс самостоятельного обслуживания, может позволить предприятию, такому как зал кафе или ресторан быстрого питания, функционировать без участия человека.

Введение

В последнее время области применения машинного зрения быстро расширяются, охватывая все больше различных сфер жизнедеятельности. На сегодняшний день для реализации систем машинного зрения в основном применяются сверточные нейронные сети, которые являются одним из видов искусственных нейронных сетей. Именно благодаря способности к обучению, искусственные нейронные сети используются для решения сложных задач классификации и регрессионного анализа.

Системы компьютерного зрения, использующие такой подход, обладают хорошей устойчивостью к изменениям масштаба, смещениям, поворотам, смене ракурса и прочим искажениям. На основе сверточных нейронных сетей реализовываются системы для беспилотного управления транспортными средствами, распознавания лиц и выявления различных заболеваний на медицинских снимках.

Актуальность данной работы обуславливается тем, что применение методов распознавания объектов на изображении может помочь уменьшить роль человеческого фактора на предприятии. Одним из таких случаев являются столовые и рестораны быстрого питания.

Целью данной работы является реализация алгоритма, способного распознавать заданные объекты на изображении.

Обзор существующих методов распознавания объектов на изображении

В рамках данной работы требуется разработать алгоритм, способный распознавать объекты на изображении, относящиеся к категориям продуктов и блюд. Визуально блюдо

может представляться как один объект из этих категорий, так и комбинацией двух объектов. Процесс распознавания объекта на изображении включает два этапа: локализацию объекта на изображении и присвоение ему соответствующей категории на основе его свойств.

В решении задачи распознавания объекта на изображении применяются различные методы, включая наложение цветных фильтров, выделение и анализ контуров, сопоставление с шаблонами, а также поиск особых точек. Однако эти методы не подходят для распознавания блюд, так как они обладают разнообразной формой и могут находиться в различных положениях на изображении. Поэтому для достижения цели работы было принято решение использовать методы машинного обучения.

Машинное обучение является разделом искусственного интеллекта, который занимается разработкой систем, способных решать задачи, решение которых ранее считалось прерогативой человека. Наиболее популярным методом идентификации объектов на изображении являются искусственные нейронные сети, особенно сверточные нейронные сети.

Эти сети обладают частичной устойчивостью к изменениям в масштабе, смещениям, поворотам, смене ракурса и прочим искажениям.

Однако, недостатком сверточных нейронных сетей является их неспособность классифицировать множество объектов на одном изображении, что является необходимым для распознавания блюд.

Для решения таких задач разработаны специальные алгоритмы на основе сверточных нейронных сетей, такие как R-CNN, YOLO и SSD, которые позволяют локализовать и классифицировать множество объектов на изображении.

Анализ принципа работы искусственной нейронной сети

Искусственная нейронная сеть – это математическая модель, построенная на основе концепции функционирования мозга. Она используется для решения разнообразных практических задач. Нейронная сеть имитирует работу нейронов в мозге, которые представляют собой простые вычислительные элементы, обменивающиеся сигналами друг с другом и способные выполнять сложные операции. Искусственные нейроны представляют функцию, которой подаются входные значения, умноженные на регулируемые веса. Затем происходит суммирование результатов и полученное значение проходит через нелинейную функцию, определяющую степень возбуждения нейрона. Обучаемость и нелинейность являются ключевыми характеристиками искусственных нейронных сетей, которые позволяют находить сложные связи между данными и учитывать опыт для улучшения результатов работы [1-12].

Структура искусственной нейронной сети представляет собой направленный граф, в котором нейроны выступают в роли узлов, а связи с весовыми коэффициентами являются дугами. Указанная структура показана на рис. 1.

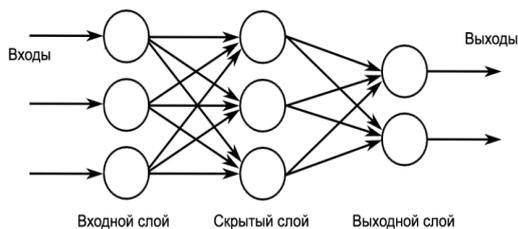


Рисунок 1 – Структура искусственной нейронной сети

Понять принцип работы искусственной нейронной сети можно на примере персептрона – одной из первых моделей нейронной сети. Модель персептрона представлена на рис. 2.

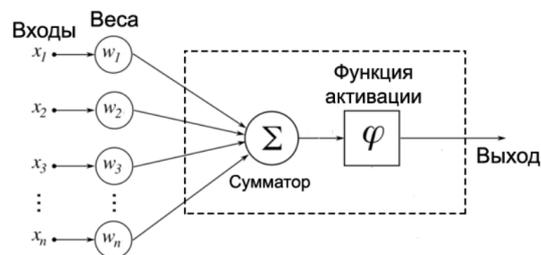


Рисунок 2 – Модель персептрона

Между входными нейронами и сумматором существуют связи с весовыми коэффициентами, которые определяют вклад каждого входа в формирование выходного значения. Сумматор вычисляет взвешенную сумму входных сигналов, умноженных на их соответствующие веса. Эта сумма затем передается в функцию активации, которая определяет активацию нейрона.

Функция активации производит нормализацию сигнала и приводит его к нужному диапазону в зависимости от типа функции активации. Без использования функции активации нейронная сеть превращается в обычную модель линейной регрессии, поскольку именно она позволяет выполнять нелинейное преобразование данных и решать более сложные задачи. Существует множество различных видов функций активации, включая ступенчатую, линейную, сигмоидальную, гиперболический тангенс и функцию усеченного линейного преобразования (ReLU), которые представлены на рис. 3.

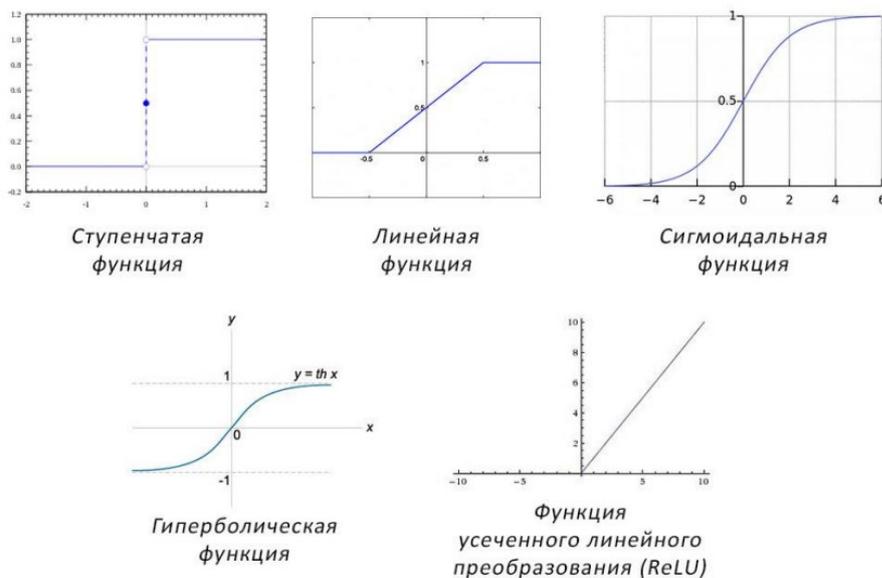


Рисунок 3 – Основные функции активации

При выборе функции активации для нейронной сети следует учитывать тип задачи, которую необходимо решить. Персептрон, самый простой вид нейронной сети, подходит для простых задач классификации, но не может справиться с более сложными задачами. Именно поэтому были разработаны многослойные нейронные сети прямого распространения, которые состоят из нейронов, организованных в слои. Нейроны каждого слоя связаны с нейронами следующего слоя, но не соединены между собой. Все слои, кроме первого и последнего, называются скрытыми слоями.

В большинстве архитектур нейронных сетей часто используется смещение во входных и скрытых слоях - нейрон, который не принимает входных данных, так как его входной сигнал всегда равен единице, однако позволяет сдвигать функцию активации в разные направления, делая модель более гибкой. Нейронная сеть с многослойными нейронами, включая нейроны смещения, изображена на рис. 4.

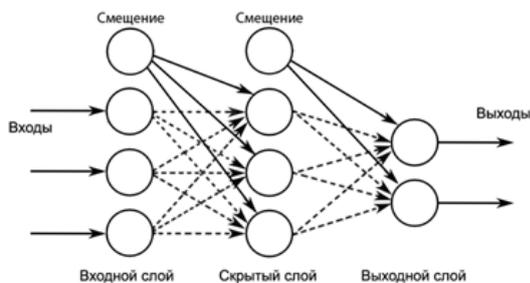


Рисунок 4 – Многослойная нейронная сеть с нейронами смещения

Существует большое число различных архитектур нейронных сетей, отличающихся количеством скрытых слоев, нейронов и видами связей между ними, каждая из которых лучше справляется со своим типом задач, однако, для того чтобы нейронная сеть научилась решать задачи разного рода, её необходимо обучать.

Особенности сверточной нейронной сети

Сверточная нейронная сеть является одной из наиболее популярных архитектур нейронных сетей, применяемая для анализа визуальных образов и классификации изображений. При восприятии различных образов, в зрительной коре активируются разные группы нейронов. В целом, архитектура сверточной нейронной сети позволяет выделять в данных различные признаки, начиная от очень простых и заканчивая более сложными.

Сверточная нейронная сеть состоит из чередующихся слоев свертки и подвыборки, после которых следуют полносвязные слои. Архитектура сверточной нейронной сети представлена на рисунке 5. Сверточный слой всегда является первым в сверточной нейронной сети и реализует операцию свертки, которая отражает реакцию отдельного нейрона на конкретную область поля зрения.

На вход сверточного слоя подается изображение в виде матрицы пикселей, размерность которой определяется размером изображения. Цветные изображения представляются тремя матрицами, каждая из которых отвечает за один из каналов цветовой модели RGB, значения матриц описывают интенсивность цвета пикселей.

В качестве нейрона выступает некое ядро свертки – матрица, элементы которой являются весовыми коэффициентами [12].

Глубина ядра свертки должна быть такой же, как и глубина изображения, к примеру для цветного изображения применяется ядро свертки, состоящее из трех матриц, каждая из которых применяется для свертки по одному из каналов цветного изображения. Операция свертки начинается с определения рецептивного поля, размер которого равен ядру свертки.

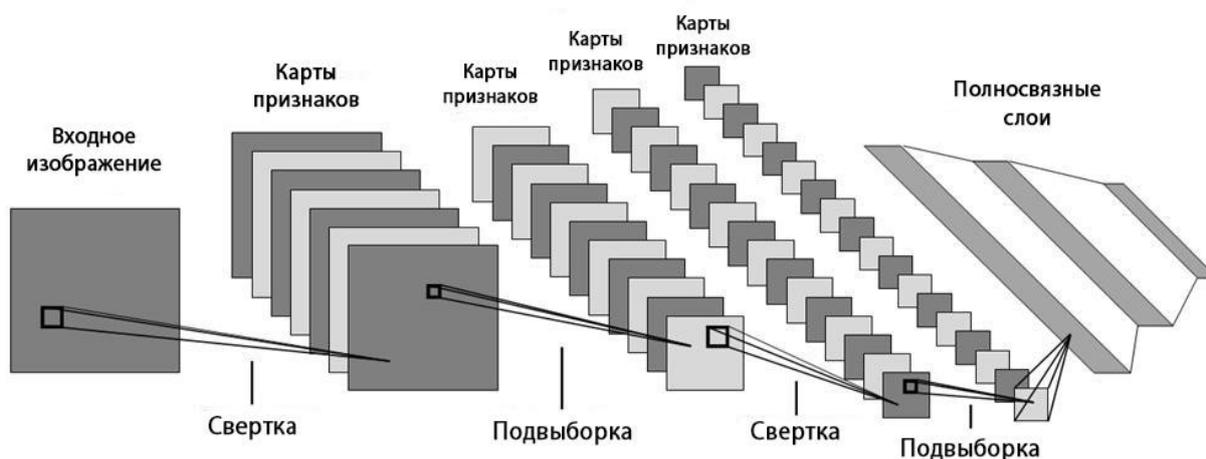


Рисунок 5 – Архитектура сверточной нейронной сети

Данное поле скользит с некоторым смещением по исходному изображению и пиксели изображения, попавшие в него, поэлементно перемножаются с ядром свертки. Элементы новой матрицы, полученной в результате перемножения, суммируются и образуют новый выходной пиксель. Операция свертки для черно-белого изображения представлена на рисунке 6.

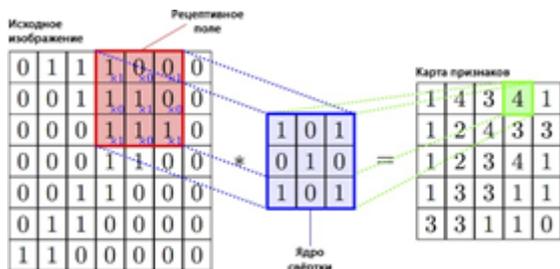


Рисунок 6 – Операция свертки

Свертка цветного изображения отличается лишь тем, что к каждому цветовому каналу применяется одна из матриц, составляющих трехмерное ядро свертки, после чего полученные матрицы суммируются в одну результирующую матрицу. Из-за того, что граничные пиксели исходного изображения не оказываются в центре рецептивного поля, матрица, полученная в результате свертки, имеет меньшую размерность, чем исходное изображение. Чтобы избежать постоянного сжатия изображения при выполнении свертки и сохранить информацию о его границах, вокруг изображения добавляется рамка из нулей, ширина которой зависит от размера ядра свертки. Данная операция называется заполнением (zero-padding). Свертка цветного изображения с заполнением представлена на рисунке 7.

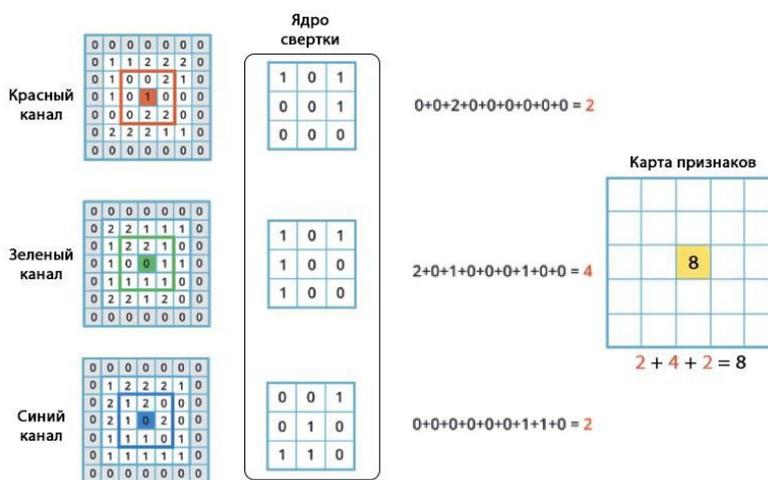


Рисунок 7 – Свертка цветного изображения с применением заполнения

Также, как и в многослойных нейронных сетях, в данной архитектуре присутствует смещение – значение, изменяемое в процессе обучения, которое складывается с каждым элементом выходной матрицы. Перед поступлением на следующий слой, полученная матрица проходит через функцию активации. Обычно в сверточных слоях в качестве функции активации используют функцию усеченного линейного преобразования, которая преобразовывает все отрицательные значения в 0, а остальные не изменяет. Данная функция была представлена на рисунке 1.3.

Итак, в результате свертки получается матрица, называемая картой признаков, на которой выделены конкретные признаки, такой как: различные прямые и кривые линии, полуокружности или более сложные признаки, в зависимости местонахождения сверточного слоя в модели нейронной сети.

После слоя свертки обычно следует слой подвыборки. Данный слой уменьшает пространственную размерность карты признаков, это достигается путем замены некоторой области пикселей одним пикселем. Необходимость этой операции объясняется тем, что важна именно информация о наличии конкретных признаков на изображении, а не их местоположение, поэтому оно сжимается до менее подробного, состоящего из доминирующих признаков [12]. Кроме того, операция подвыборки уменьшает количество параметров сверточной сети, тем самым снижая вычислительную нагрузку.

При выполнении операции подвыборки учитываются два параметра: размер ядра подвыборки, скользящего по изображению, которое сворачивает попавшие в него пиксели до 1 пикселя и размер шага в пикселях, на которое сдвигается ядро подвыборки. Чаще всего используют пара значений параметров: 2x2,

которая уменьшает размерность карты признаков в два раза.

Для того, чтобы выявить сложные признаки на изображении, сверточные сети содержат множество чередующихся слоев свертки и подвыборки. Таким образом, с каждой парой слоев свертки глубина карты признаков изменяется в зависимости от числа ядер свертки, а их размерность уменьшается.

Конечными слоями сверточной нейронной сети являются полносвязные слои, с помощью которых происходит классификация объекта на изображении. Перед подачей полученной карты признаков на полносвязный слой, происходит объединение слоев карты признаков в вектор, где каждый элемент показывает вероятность присутствия конкретного признака на изображении. К примеру, чтобы изображение было классифицировано как лицо, вероятность присутствия таких признаков как глаза, рот и нос должна быть высокой [10]. Последний полносвязный слой содержит количество нейронов, равное количеству определяемых классов и с помощью выбранной функции активации выводит вероятности присутствия каждого класса на изображении.

Реализация алгоритма ssd для локализации возгораний

Для реализации алгоритма SSD был выбран высокоуровневый кроссплатформенный объектно-ориентированный язык программирования Python. Данный язык программирования является мощным инструментом, так как содержит множество библиотек, реализующих программные решения для разработки различных систем, в частности для решения задач машинного обучения [5].

Для реализации и обучения нейронной сети, используемой в алгоритме SSD, была выбрана библиотека машинного обучения TensorFlow версии 2.0. Она включает в себя множество готовых решений и алгоритмов, таких как функции оптимизации, функции потерь, различные метрики, а также инструменты для проектирования различных нейронных сетей [10]. Для работы с данной библиотекой все обрабатываемые ею данные представляются в виде специальных контейнеров, называемых тензорами – многомерными массивами. На данный момент TensorFlow является наиболее популярной библиотекой для машинного обучения.

В первую очередь при реализации алгоритма для распознавания блюд на основе архитектуры SSD были реализованы сверточные слои, используемые в модели нейронной сети. Построение слоёв модели выполняется с помощью встроенного в Tensorflow

высокоуровневого API для построения моделей под названием Keras.

Создание сверточных слоев происходит с помощью метода «Conv2D», который в качестве параметров принимает количество ядер свертки, их размерность, размер граничного заполнения, расширение и функцию активации, используемую после свертки. Для создания слоев подвыборки по максимальному значению используется метод «MaxPool2D», принимающий аналогичные параметры за исключением расширения и функции активации. Для задачи входных данных нейронной сети используется метод Input, который создает входной тензор определенного размера. Помимо входного тензора в данную функцию необходимо передать выходные данные последнего слоя. Программный код реализации слоев сверточной сети VGG16 представлен на рисунке 8.

```
def create_vgg16_layers():
    vgg16_conv4 = [
        layers.Conv2D(64, 3, padding='same', activation='relu'),
        layers.Conv2D(64, 3, padding='same', activation='relu'),
        layers.MaxPool2D(2, 2, padding='same'),

        layers.Conv2D(128, 3, padding='same', activation='relu'),
        layers.Conv2D(128, 3, padding='same', activation='relu'),
        layers.MaxPool2D(2, 2, padding='same'),

        layers.Conv2D(256, 3, padding='same', activation='relu'),
        layers.Conv2D(256, 3, padding='same', activation='relu'),
        layers.Conv2D(256, 3, padding='same', activation='relu'),
        layers.MaxPool2D(2, 2, padding='same'),

        layers.Conv2D(512, 3, padding='same', activation='relu'),
        layers.Conv2D(512, 3, padding='same', activation='relu'),
        layers.Conv2D(512, 3, padding='same', activation='relu'),
        layers.MaxPool2D(2, 2, padding='same'),

        layers.Conv2D(512, 3, padding='same', activation='relu'),
        layers.Conv2D(512, 3, padding='same', activation='relu'),
        layers.Conv2D(512, 3, padding='same', activation='relu'),
    ]

    vgg16_conv7 = [
        layers.MaxPool2D(3, 1, padding='same'),
        layers.Conv2D(1024, 3, padding='same', dilation_rate=6, activation='relu'),
        layers.Conv2D(1024, 1, padding='same', activation='relu'),
    ]
```

Рисунок 8 - Программный код реализации слоев сверточной сети VGG16

Дополнительные слои, а также слои для классификации и регрессии реализованы таким же образом и будут приведены в приложении. Для того, чтобы использовать эти слои при прямом проходе, был создан класс для модели SSD. Данный класс содержит метод инициализации модели, в котором загружаются веса, настроенные в процессе долгого обучения на наборе данных ImageNet, содержащим порядка 15 миллионов размеченных изображений, разделенных на десятки тысяч классов. Данный подход позволяет ускорить процесс обучения рассматриваемой архитектуры для распознавания новых классов объектов.

Программный код функции, осуществляющей прямой проход в модели SSD представлен на рисунке 9.

```
def call(self, x):  
    """ Прямой проход  
    """  
    confs = []  
    locs = []  
    head_idx = 0  
    for i in range(len(self.vgg16_conv4.layers)):  
        x = self.vgg16_conv4.get_layer(index=i)(x)  
        if i == len(self.vgg16_conv4.layers) - 5:  
            conf, loc = self.compute_heads(self.batch_norm(x), head_idx)  
            confs.append(conf)  
            locs.append(loc)  
            head_idx += 1  
  
    x = self.vgg16_conv7(x)  
  
    conf, loc = self.compute_heads(x, head_idx)  
  
    confs.append(conf)  
    locs.append(loc)  
    head_idx += 1  
  
    for layer in self.extra_layers:  
        x = layer(x)  
        conf, loc = self.compute_heads(x, head_idx)  
        confs.append(conf)  
        locs.append(loc)  
        head_idx += 1  
  
    confs = tf.concat(confs, axis=1)  
    locs = tf.concat(locs, axis=1)  
  
    return confs, locs
```

Рисунок 9 - Программный код функции, осуществляющей прямой проход в модели SSD

Данная функция принимает на вход изображение и совершает прямой проход для предсказания ограничивающих рамок объектов на изображении и их классов.

Генерация наборов обучающий данных происходит с помощью функции «create_batch_generator», предоставляющей объекты класса генератора тренировочных и проверочных данных. Эти объекты-генераторы позволяют в процессе обучения получать наборы данных, состоящие из изображений, меток классов для всех рамок по умолчанию, а также смещений для положительных рамок по умолчанию относительно реальных рамок объекта.

Метод генерации использует специальный класс «VOCDataset», который подготавливает данные для обучения: считывает из обучающего набора данных тренировочные и проверочные изображения, а также метки классов с ограниченными прямоугольниками, изменяет размеры изображения и находит смещения и метки классов для положительных рамок по умолчанию [7]. Создание генератора обучающих наборов данных происходит с помощью метода «Dataset.from_generator» библиотеки TensorFlow.

Для автоматического дифференцирования обучаемых переменных при обратном распространении ошибки, необходимо

использовать специальный диспетчер контекста «tf.GradientTape()». Внутри данного контекста используется функция для расчёта ошибок модели SSD. Получаемые с помощью неё ошибки классификации и локализации суммируются, образуя общую ошибку детектора для одного обучающего примера [4]. После этого находится сумма квадратов ошибок для всех примеров обучающего пакета и делится на их количество. Общая ошибка используется для нахождения градиента, который используется методом оптимизации для уменьшения ошибки обучаемой модели. В качестве оптимизатора используется стохастический градиентный спуск, который задается с помощью функции библиотеки TensorFlow «SDG». В качестве параметров метода оптимизации передается значение скорости обучения и значения импульса, который используется для учета уровня влияния градиентов, рассчитанных на предыдущих шагах обучения. Данный параметр позволяет обновлять веса более сглажено, что способствует более быстрой оптимизации ошибки модели. Рекомендуется использовать импульс равный 0,9 [11].

Заключение

В данной работе исследовался вопрос распознавания блюд на изображении на основе сверточных нейронных сетей.

Проведен анализ существующих методов распознавания объектов на изображении и сделан вывод, что для распознавания блюд наиболее подходящими являются методы, основанные на машинном обучении, а именно сверточные нейронные сети. Рассмотрены основные принципы работы искусственных нейронных сетей, особенности их построения, а также методы, с помощью которых происходит их обучение. Кроме того, подробно разобран процесс применения сверточных нейронных сетей для классификации объекта на изображении.

Для локализации и классификации объектов на изображении принято решение использовать алгоритм Single Shot MultiBox Detector, в основу которого входят сверточные нейронные сети. Данный алгоритм выбран, поскольку он обнаруживает объекты за один прямой проход нейронной сети и достигает наилучшего баланса между точностью и быстродействием, что является важным при распознавании. Также описаны основные принципы работы алгоритма SSD и произведена его реализация на языке Python с помощью инструментов библиотеки машинного обучения TensorFlow.

Для обучения модели сверточной нейронной сети, входящей в состав алгоритма SSD, вручную собран и размечен обучающий

набор данных, состоящий из 2000 изображений. Обучение сверточной нейронной сети проходило в течение 300 эпох, в результате чего минимальная средняя ошибка предсказания составила 0,4.

Таким образом, реализован алгоритм на основе сверточных нейронных сетей, способный обнаруживать на изображении выбранные классы объектов, с довольно высокой точностью. Использование данного алгоритма для анализа видеопотоков, получаемых с касс самостоятельного обслуживания (КСО), может позволить предприятию (залу кафе или ресторану быстрого питания) функционировать без участия человека.

Литература

1. Бурков, А. Машинное обучение без лишних слов / А. Бурков. – СПб.: Питер, 2020. – 192 с.
2. Вьюгин, В. Математические основы машинного обучения и прогнозирования / В. Вьюгин. - МЦНМО, 2014. - 304 с.
3. Гелиг, А. Введение в математическую теорию обучаемых распознающих систем и нейронных сетей. Учебное пособие / А. Гелиг, А. Матвеев - Издательство СПбГУ, 2014. – 224 с.
4. Документация по библиотеке машинного обучения TensorFlow 2.0: официальный сайт TensorFlow [Электронный ресурс]. - URL: https://www.tensorflow.org/versions/r2.0/api_docs/python/
5. Документация по языку программирования Python : официальный сайт Python [Электронный ресурс] -. URL: <https://www.python.org/doc/>.
6. Szegedy, Ch. Scalable, High-Quality Object Detection [Электронный ресурс] // arXiv: открытый архив научных статей. - URL: <https://arxiv.org/abs/1412.1441>
7. Ryo Takahashi. Data Augmentation using Random Image Cropping and Patching for Deep CNNs [Электронный ресурс] // arXiv: открытый архив научных статей. - URL: <https://arxiv.org/abs/1811.09030>.
8. Wei Liu. SSD: Single Shot MultiBox Detector [Электронный ресурс] // arXiv: открытый архив научных статей. - URL: <https://arxiv.org/abs/1512.02325>
9. Abu-Mostafa, Y. Learning From Data / Yaser S. Abu-Mostafa, Malik Magdon-Ismail, Hsuan-Tien Lin – AMLBook. – 2012. - Jan. -С. 213.
10. Eddison L. Python Machine Learning: A Technical Approach To Python Machine Learning For Beginners / Leonard Eddison - CreateSpace Independent Publishing Platform. – 2018. - Mar. - С. 292.
11. Geron, A. Hands-On Machine Learning with Scikit-Learn and TensorFlow / Aurelien Geron // O'Reilly Media. – 2017. - Mar. - С. 566.
12. Goodfellow, I. Deep Learning (Adaptive Computation and Machine Learning series) / Ian Goodfellow, Yoshua Bengio, Aaron Courville // The MIT Press, 2016. - Nov. - С. 800.

Волгушева А. И., Мальчева Р. В. Применение сверточных нейронных сетей для распознавания объектов на изображении. Выполнен анализ принципов работы искусственных нейронных сетей, сферы их применения для распознавания объектов на изображении. Выбран и реализован алгоритм на основе сверточных нейронных сетей, способный с довольно высокой точностью обнаруживать на изображении выбранные классы объектов. Использование данного алгоритма для анализа видеопотоков, получаемых с касс самостоятельного обслуживания, может позволить предприятию, такому как зал кафе или ресторан быстрого питания, функционировать без участия человека.

Ключевые слова: разработка, нейронная сеть, алгоритм, объект, анализ.

Volgusheva A. I., Malcheva R. V. Application of convolutional neural networks for object recognition in an image. The analysis of the principles of artificial neural networks, the scope of their application for recognizing objects in the image is carried out. An algorithm based on convolutional neural networks has been selected and implemented, capable of detecting selected classes of objects in an image with fairly high accuracy. Using this algorithm to analyze video streams received from self-service ticket offices can allow an enterprise, such as a cafe hall or a fast food restaurant, to function without human intervention.

Keywords: development, neural network, algorithm, object, analysis.

Статья поступила в редакцию 15.06.2024
Рекомендована к публикации профессором Зори С. А.

Обработка текста методами естественного языка

Л. В. Рудак, С. А. Зори

E-mail: semerikov2917@yandex.ru, ik.ivt.rec@mail.ru

Аннотация

В работе рассматриваются методы обработки текста с использованием естественного языка (NLP), которые играют ключевую роль в современном мире информационных технологий. Статья охватывает основные концепции и техники NLP, такие как токенизация, стемминг, лемматизация, удаление стоп-слов, использование регулярных выражений, а также методы представления текста, включая Bag of Words и TF-IDF. Особое внимание уделено анализу тональности, машинному переводу, автоматическому резюмированию и чат-ботам, которые являются важными направлениями в области NLP.

Введение

Обработка естественного языка является одной из ключевых областей искусственного интеллекта, направленной на взаимодействие между компьютерами и людьми с использованием естественного языка. В последние годы, благодаря достижениям в области машинного обучения и росту вычислительных мощностей, методы NLP значительно продвинулись вперед, предоставляя новые возможности для анализа, интерпретации и генерации текстовых данных [1].

Основная цель NLP заключается в создании систем, которые могут понимать и генерировать человеческий язык таким образом, чтобы это было полезно для различных прикладных задач, таких как автоматическое резюмирование текстов, машинный перевод, распознавание речи, анализ тональности, классификация текстов и многое другое. Эти задачи требуют использования различных методов и алгоритмов, которые могут обрабатывать и анализировать огромные объемы текстовых данных.

Методы NLP опираются на широкий спектр технологий и подходов, включая токенизацию, стемминг, лемматизацию, удаление стоп-слов, векторизацию текста и использование сложных моделей глубокого обучения. Одним из ключевых аспектов обработки текста является преобразование неструктурированных текстовых данных в структурированную форму, которая может быть использована для дальнейшего анализа и обработки. Это преобразование включает в себя извлечение значимой информации, устранение избыточности и учет контекста слов в тексте [2].

Таким образом, развитие методов обработки текста с помощью NLP продолжает активно трансформировать способы взаимодействия человека с информацией, делая

этот процесс более эффективным и интуитивным.

Основные концепции и методы NLP

Процесс обработки языка с помощью NLP включает несколько ключевых этапов, таких как предобработка текста, синтаксический и семантический анализ, извлечение сущностей, анализ намерений и генерация ответов. Каждый из этих этапов играет важную роль в обеспечении точности и эффективности систем обработки информации. В предобработке текста важными шагами являются токенизация, нормализация и удаление стоп-слов, что позволяет структурировать и очистить исходные данные. Синтаксический анализ направлен на понимание грамматической структуры текста, а семантический анализ — на интерпретацию его смысла.

Извлечение сущностей (Named Entity Recognition, NER) и анализ намерений (Intent Recognition) являются одними из наиболее важных задач в NLP, так как они помогают системе понимать, какие объекты и действия упоминаются в тексте. Наконец, генерация ответов (Text Generation) позволяет системе формулировать ответы на запросы пользователей на естественном языке, что делает взаимодействие с системой более дружелюбным и эффективным.

Токенизация

Токенизация предложений — это процесс разделения строки текста на составляющие предложения. Задача на первый взгляд является не самой сложной, потому что в русском и многих других языках можно разделять предложения всякий раз, когда видим знак препинания. Токенизация слов — это процесс разделения строки текста на составляющие ее слова.

Токенизация является фундаментальным шагом в процессе обработки естественного языка. Выбор метода токенизации зависит от конкретной задачи и характеристик текста. Программные методы, такие как регулярные выражения, и специализированные библиотеки на языке Python, такие как NLTK и SpaCy, предоставляют широкий спектр инструментов для эффективной токенизации слов и предложений, что значительно упрощает дальнейший анализ и обработку текстовых данных [3].

Стемминг и лемматизация

В обработке естественного языка стемминг и лемматизация являются важными методами для нормализации текста. Они помогают привести слова к их базовым или корневым формам, что упрощает дальнейший анализ и обработку данных [4].

Стемминг — это процесс уменьшения слова до его основы или корня (стема), удаляя суффиксы и окончания. Это простая и быстрая техника, которая часто применяется в задачах извлечения информации и поиска данных.

Лемматизация — это процесс приведения слова к его канонической форме (лемме), используя знания о морфологии и части речи слова. В отличие от стемминга, лемматизация более сложная и точная, так как учитывает контекст и грамматические характеристики слова.

Стемминг и лемматизация являются важными инструментами в арсенале методов предобработки текста в NLP. Стемминг обеспечивает простое и быстрое уменьшение слов до их основ, тогда как лемматизация предоставляет более точные и контекстуально осведомленные результаты.

Стоп-слова

Стоп-слова — это слова, которые часто встречаются в тексте, но не несут значимой смысловой нагрузки для анализа. В контексте обработки естественного языка стоп-слова обычно удаляются из текста на этапе предобработки, чтобы улучшить эффективность и точность последующих операций, таких как классификация текста, извлечение информации и поиск.

Подходы к удалению стоп-слов:

1. Использование предопределенных списков: множество библиотек NLP предоставляют списки стоп-слов для различных языков. Например, библиотеки NLTK, SpaCy и sklearn содержат встроенные списки стоп-слов для английского и других языков.

2. Создание пользовательских списков: в зависимости от специфики задачи и корпуса данных, можно создать свои собственные списки стоп-слов, добавляя или исключая слова по мере необходимости.

3. Адаптивные методы: некоторые подходы предполагают автоматическое определение стоп-слов на основе их частотных характеристик в корпусе. Например, слова, которые встречаются очень часто или очень редко, могут быть помечены как стоп-слова.

Regex

Регулярные выражения (regex) — это последовательности символов, которые определяют шаблоны поиска в тексте. Регулярные выражения позволяют задавать сложные критерии поиска, включая поиск по шаблонам, замены и валидацию строк. Это мощный инструмент для работы с текстом в различных задачах, от простого поиска до сложной предобработки данных в NLP.

Bag-of-words

Метод "Bag of Words" (BoW) — один из наиболее простых и популярных методов представления текста в задачах обработки естественного языка. Этот метод преобразует текстовые данные в числовые векторы, что позволяет использовать их в моделях машинного обучения. Этот метод может применяться после того, как была произведена токенизация текста и сформирован словарь, состоящий из слов, наличие которых в тексте нас интересует.

Каждое предложение обрабатываемого текста в этом методе представляется в качестве вектора из нулей и единиц, имеющего длину, равную количеству слов в словаре интересующих нас слов, где единица говорит про то, что слово присутствует в предложении, а ноль — про его отсутствие [5].

Чем больший размер текста нужно обработать с помощью этого метода, тем больше станет словарь и размер вектора, который будет включать в себя много нулей. Чтобы избежать этого, можно уменьшить количество слов в словаре или создать более сложный словарь.

Метод BoW также можно расширить с помощью n-грамм для более детального учета контекста слов в тексте. N-граммы — это последовательности из n слов (или символов), которые могут предоставлять более богатую информацию о структуре и содержании текста по сравнению с отдельными словами. При использовании n-грамм словарь будет содержать не только отдельные слова, но и последовательности слов, что позволит учитывать более сложные зависимости и контексты.

При использовании n-грамм словарь будет содержать не только отдельные слова, но и последовательности слов, что позволит учитывать более сложные зависимости и контексты.

TF-IDF

TF-IDF (Term Frequency-Inverse Document Frequency) — это статистическая мера,

используемая для оценки значимости слова в документе по отношению к коллекции документов. Этот метод позволяет более точно учитывать важность слов в контексте, чем простой метод "Bag of Words" (BoW) [6].

Основные компоненты TF-IDF:

TF (Term Frequency): Частота слова в документе. Она измеряет, насколько часто слово встречается в данном документе, по формуле (1).

$$TF(t, d) = \frac{n_t}{\sum_k n_k}, \quad (1)$$

где n_t это число вхождений слова t в документ;

$\sum_k n_k$ – общее число слов в данном документе.

IDF (Inverse Document Frequency): Обратная частота документов. Она измеряет, насколько слово редкое или распространенное в коллекции документов, по формуле (2).

$$IDF(t, D) = \log \left(\frac{|D|}{|\{d_i \in D \mid t \in d_i\}|} \right), \quad (2)$$

где $|D|$ – число документов в коллекции;

$|\{d_i \in D \mid t \in d_i\}|$ – число документов из коллекции D , в которых встречается t (когда $n_t \neq 0$).

TF-IDF: Произведение TF и IDF для слова. Оно показывает значимость слова в документе с учетом его распространенности в коллекции документов (формула 3).

$$TF - IDF(t, d, D) = TF(t, d) \times IDF(t, D). \quad (3)$$

Практическое применение методов NLP

Обработка естественного языка находит широкое применение в различных сферах, улучшая процессы и взаимодействие между людьми и машинами. Рассмотрим несколько ключевых областей применения методов NLP.

Анализ тональности

Анализ тональности (Sentiment Analysis) — это метод обработки естественного языка, направленный на определение эмоциональной окраски текста. Он позволяет выявлять позитивное, негативное или нейтральное отношение в текстовых данных. Анализ тональности широко применяется в бизнесе, маркетинге, социальных науках и многих других областях [7].

Приведем примеры использования анализа тональности.

Обслуживание клиентов: Анализ отзывов клиентов на продукцию или услуги для выявления общих настроений и удовлетворенности.

Социальные медиа: Мониторинг социальных сетей для оценки общественного мнения о бренде, продукте или событии.

Маркетинговые исследования: Анализ тональности отзывов и комментариев для понимания потребительских предпочтений и улучшения маркетинговых стратегий.

Политический анализ: Оценка общественного мнения о политических деятелях или инициативах на основе комментариев в социальных сетях и других источниках.

Методы анализа тональности

Лексиконные методы:

- основаны на предварительно созданных словарях, в которых каждому слову присваивается определенная эмоциональная оценка;

- примеры: SentiWordNet, AFINN, VADER (Valence Aware Dictionary and sEntiment Reasoner).

Машинное обучение:

- использование алгоритмов машинного обучения для классификации текста на основе тональности;

- примеры алгоритмов: Наивный Байес (Naive Bayes), Метод опорных векторов (SVM), Логистическая регрессия;

- требует предварительной разметки текстов для обучения модели.

Глубокое обучение:

- применение нейронных сетей для анализа тональности, что позволяет учитывать сложные зависимости и контексты в тексте;

Примеры моделей: Рекуррентные нейронные сети (RNN), Долгосрочная краткосрочная память (LSTM), Трансформеры (BERT, GPT);

- модели глубокого обучения часто демонстрируют высокую точность, особенно при наличии большого объема данных для обучения.

Машинный перевод

Машинный перевод (Machine Translation, MT) — это процесс автоматического перевода текста с одного языка на другой с помощью компьютерных программ. Это одна из наиболее важных и широко используемых задач в области обработки естественного языка, которая имеет множество практических применений.

Принцип работы машинного перевода

Машинный перевод включает в себя несколько этапов:

1. Предварительная обработка текста: исходный текст подвергается предварительной обработке, которая включает в себя токенизацию (разделение текста на отдельные слова или фразы), удаление стоп-слов (например, предлогов, союзов) и нормализацию (приведение слов к нормальной форме).

2. Построение модели: для выполнения машинного перевода используются различные модели, от статистических методов до современных нейронных сетей. Эти модели

обучаются на больших корпусах параллельных текстов на разных языках.

3. Выравнивание: прежде чем перевести предложение на целевой язык, модель должна определить соответствие между словами и фразами исходного и целевого текста. Этот процесс называется выравниванием.

4. Перевод: используя полученные выравнивания и обученную модель, производится перевод исходного текста на целевой язык.

5. Постобработка: после перевода текст может быть подвергнут постобработке для улучшения качества перевода, например, для исправления грамматических ошибок или улучшения стиля перевода [8].

Применение машинного перевода

1. Коммерческий машинный перевод: В сфере бизнеса машинный перевод используется для перевода документов, писем, веб-сайтов и других текстовых материалов на разные языки для общения с клиентами и партнерами по всему миру.

2. Поисковые системы: Машинный перевод используется в поисковых системах для перевода результатов поиска или текстов рекламы на разные языки для максимизации охвата аудитории.

3. Социальные сети и коммуникация: В социальных сетях машинный перевод позволяет пользователям из разных стран общаться и взаимодействовать на их родном языке.

4. Автоматический переводчик: Машинный перевод используется в автоматических переводчиках для устного перевода разговоров и диалогов в реальном времени.

Технологии машинного перевода

1. Статистический машинный перевод: Основан на статистических моделях, которые анализируют большие объемы параллельных текстов на разных языках и извлекают статистические зависимости между ними.

2. Нейронные сети: Современные методы машинного перевода широко используют глубокое обучение и нейронные сети, такие как рекуррентные нейронные сети (RNN), сверточные нейронные сети (CNN) и трансформеры. Эти модели способны обрабатывать большие объемы текста и захватывать сложные зависимости между словами и фразами.

Автоматическое резюмирование

Автоматическое резюмирование — это процесс создания краткого и содержательного обзора или резюме из исходного текста. Этот процесс позволяет выделять ключевые и информативные аспекты текста, делая его более

доступным и понятным для пользователей. Приведем некоторые особенности автоматического резюмирования (AR).

Принцип работы AR

1. Предварительная обработка текста: исходный текст подвергается предварительной обработке, которая может включать в себя токенизацию, удаление стоп-слов, лемматизацию и выделение предложений.

2. Выделение ключевых фраз и предложений: с помощью методов NLP выделяются ключевые фразы и предложения, которые наиболее информативны и репрезентативны для содержания текста.

3. Оценка важности: каждая фраза или предложение оценивается по степени их важности и информативности в тексте.

4. Генерация резюме: на основе оценок важности генерируется краткое резюме, включающее наиболее значимые и информативные аспекты исходного текста.

Применение AR

1. Сжатие текста: автоматическое резюмирование позволяет сокращать длинные тексты, делая их более компактными и удобными для чтения.

2. Информационные порталы: на информационных порталах автоматически создаются краткие обзоры новостей и статей, позволяя пользователям быстро получать основную информацию.

3. Анализ данных: в анализе данных автоматическое резюмирование помогает выделять ключевые аспекты и выводы из больших объемов текстовых данных.

4. Обработка документов: в бизнесе автоматическое резюмирование используется для обработки документов, отчетов и писем, помогая управлять информационными потоками.

Технологии AR

1. Извлечение ключевых слов: простые методы выделения ключевых слов на основе частотности и важности слов в тексте.

2. Извлечение ключевых предложений: анализ текста с использованием методов NLP для выделения ключевых предложений, содержащих наиболее важную информацию.

3. Генерация сжатого текста: использование алгоритмов для генерации кратких резюме на основе выделенных ключевых фраз и предложений.

4. Использование нейронных сетей: современные методы автоматического резюмирования используют глубокое обучение и нейронные сети для создания более точных и информативных резюме.

Чат-боты

Чат-боты — это программные агенты, способные автоматически взаимодействовать с

пользователями через текстовые интерфейсы, такие как мессенджеры, веб-сайты, приложения и другие. Они используются для решения различных задач, от предоставления информации и обработки заказов до выполнения операций в реальном времени.

Принцип работы:

1. Понимание запроса: чат-боты анализируют текстовые запросы пользователей и пытаются понять их смысл с помощью алгоритмов обработки естественного языка.

2. Генерация ответа: на основе понимания запроса чат-бот генерирует и отправляет ответ пользователю. Этот ответ может быть текстовым сообщением, ссылкой, изображением или даже действием.

3. Интерактивность: Некоторые чат-боты могут проводить диалог с пользователем, задавать дополнительные вопросы или запрашивать уточнения для более точного выполнения задачи.

Примеры применения:

Чат-боты используются в различных сферах, таких как клиентская поддержка, бронирование билетов, заказ товаров и услуг, проведение опросов, обучение и обучение, медицинская помощь и многое другое.

Заключение

Обработка текста методами естественного языка стала неотъемлемой частью современной технологии, играя ключевую роль в различных аспектах жизни и бизнеса. Эти методы позволяют компьютерам понимать, интерпретировать и генерировать человеческий язык, что открывает широкие возможности для автоматизации и улучшения коммуникации.

Анализ текста с использованием методов NLP позволяет автоматизировать множество процессов, включая анализ отзывов клиентов, мониторинг социальных сетей, улучшение поиска информации и поддержку многоязычного общения. Примеры практического применения этих методов демонстрируют их значимость в различных отраслях, таких как маркетинг, здравоохранение, образование и правоприменение.

Было рассмотрено несколько ключевых направлений NLP. Каждый из рассмотренных методов предоставляет уникальные инструменты для обработки и анализа текстовых данных, что делает их незаменимыми в разработке современных приложений.

Особое внимание в статье было уделено практическому применению методов NLP, в частности, в области анализа тональности, машинного перевода, автоматического

резюмирования и чат-ботов. Эти технологии значительно улучшают взаимодействие между людьми и машинами, обеспечивая эффективную и естественную коммуникацию.

Несмотря на значительные достижения, NLP продолжает развиваться, сталкиваясь с новыми вызовами и открывая новые перспективы. Будущие исследования и разработки авторов будут направлены на улучшение точности и эффективности существующих методов, а также на создание новых подходов для решения более сложных задач. В этом контексте, NLP остается динамичной и важной областью, имеющей потенциал для значительного влияния на технологии и общество в целом.

Литература

1. Обработка естественного языка – [Электронный ресурс] / Интернет-ресурс. - Режим доступа: https://neerc.ifmo.ru/wiki/index.php?title=Обработка_естественного_языка - Загл. с экрана (дата обращения: 24.05.24)
2. Правильный NLP: как работают и что умеют системы обработки естественного языка – [Электронный ресурс] / Интернет-ресурс. - Режим доступа: <https://tproger.ru/articles/natural-language-processing/> - Загл. с экрана (дата обращения: 24.05.24)
3. Jurafsky, D., & Martin, J. H.. Speech and Language Processing (3rd ed.). - Pearson, 2021.
4. Thomas Landauer, Peter W. Foltz, & Darrell Laham. Introduction to Latent Semantic Analysis (англ.) // Discourse Processes (англ.) русск.: journal. – 1998. – Vol. 25. – Pp. 259–284. – DOI: 10.1080/01638539809545028.
5. Pennington, J., Socher, R., & Manning, C. D. Glove: Global Vectors for Word Representation // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). – PP. 1532-1543.
6. Mark Needham. Scikit-learn: TF/IDF and cosine similarity for computer science papers. – 2017. – – [Электронный ресурс] / Интернет-ресурс. - Режим доступа: <https://markneedham.com/blog/2016/07/27/scikit-learn-tfidf-and-cosine-similarity-for-computer-science-papers/> - Загл. с экрана (дата обращения: 24.05.24);
7. Pang, B., & Lee, L. Opinion Mining and Sentiment Analysis // Foundations and Trends in Information Retrieval, 2008. – Т. 2(1-2). – P. 1-135.
8. Koehn, P. Statistical Machine Translation // Cambridge University Press, 2010.

Рудак Л.В., Зори С.А. Обработка текста методами естественного языка. В работе рассматриваются методы обработки текста с использованием естественного языка

(NLP), которые играют ключевую роль в современном мире информационных технологий. Статья охватывает основные концепции и техники NLP, такие как токенизация, стемминг, лемматизация, удаление стоп-слов, использование регулярных выражений, а также методы представления текста, включая Bag of Words и TF-IDF. Особое внимание уделено анализу тональности, машинному переводу, автоматическому резюмированию и чат-ботам, которые являются важными направлениями в области NLP.

Ключевые слова: *обработка естественного языка, машинное обучение, токенизация, искусственный интеллект, нейронные сети*

Rudak L.V., Zori S.A. Text processing using natural language methods. *The paper examines text processing methods using natural language (NLP), which plays a key role in the modern world of information technology. The article covers basic NLP concepts and techniques such as tokenization, stemming, lemmatization, stop word removal, regular expressions, and text representation methods including Bag of Words and TF-IDF. Particular attention is paid to sentiment analysis, machine translation, automatic summarization and chatbots, which are important areas in the field of NLP.*

Keywords: *natural language processing, machine learning, tokenization, artificial intelligence, neural networks*

*Статья поступила в редакцию 20.06.2024
Рекомендована к публикации профессором Федяевым О. И.*

УДК 004.93'12

Видеорегистрация присутствия студентов в аудитории на основе нейросетевого распознавания лиц

А. А. Суханов, Д. Э. Баев, О. И. Федяев

E-mail: studysukhanov@mail.ru, azo.cw@yandex.ru, olegfedyayev@yahoo.com

Аннотация:

В данной статье описана архитектура свёрточной нейронной сети VGGFace, на основе которой разработана схема компьютерного распознавания человека по его лицу. Выполнена программная реализация системы, которая осуществляет автоматическое ведение электронного журнала группы. Проведены эксперименты по видеорегистрации студентов при входе в аудиторию с помощью компьютерного зрения.

Введение

Искусственный интеллект находит все большее применение в различных сферах человеческой деятельности [1], в том числе и в образовании [2-5].

Актуальность данной задачи обусловлена, во-первых, потерями времени преподавателя, которые возникают при ручной регистрации присутствия большого количества учащихся в аудитории (в потоке из 70 человек потери на «переключку» составляют в среднем 85 мин в семестре и даже больше); во-вторых, «переключка» проходит шумно и не всегда достоверно [6].

Основные трудности компьютерного распознавания лиц в реальном времени связаны с быстрой изменчивостью изображений объектов в видеопотоке: положение, размер и ракурс лица в кадре, освещение и т. д. В настоящее время большие перспективы в преодолении перечисленных проблем связывают с применением глубоких нейронных сетей. К этому классу относится многослойная свёрточная нейронная сеть.

На данный момент свёрточная нейронная сеть и её модификации считаются лучшими по точности и скорости распознавания объектов на изображении.

Более того, распознавание лиц из видеопотока с камеры показывает, что нейронные сети с такой архитектурой способны работать в режиме реального времени даже на устройствах с ограниченными ресурсами [7].

Поэтому целью данной работы является оценка возможности реализации нейросетевого распознавания лиц из видеопотока на базе существующих инструментальных средств и создание системы оперативного визуального контроля присутствия студентов на учебных занятиях, что подчёркивает её уникальность.

Выделение признаков во входном изображении свёрточной нейронной сетью

Свёрточная нейронная сеть – это специализированный тип нейросетевой модели, предназначенной для работы с данными двумерных изображений, хотя они могут использоваться и с одномерными, и с трёхмерными данными.

Центральным элементом свёрточной нейронной сети является свёрточный слой, благодаря которому сеть и получила свое название. Этот слой выполняет операцию, называемую «свёрткой».

В контексте свёрточной нейронной сети свёртка – это линейная операция, которая включает в себя умножение набора весов на вход, как в традиционной нейронной сети. Учитывая, что техника была разработана для двумерного ввода, умножение выполняется между массивом входных данных и двумерным массивом весов, называемым фильтром или ядром.

Фильтр меньше входных данных, и тип умножения, применяемый между участком входных данных, представляет собой точечное произведение. Точечное произведение – это умножение по элементам между участками входных данных и фильтра, которые затем суммируются, в результате чего всегда получается одно значение. Поскольку в результате получается одно значение, эту операцию часто называют «скалярным произведением».

Использование фильтра меньшего размера, чем входные данные, является умышленным, поскольку это позволяет нам умножать один и тот же фильтр, набор весов, на входной массив несколько раз в разных точках входных данных. В частности, фильтр систематически применяется к каждой перекрывающейся части или участку входных

данных размером с фильтр, слева направо, сверху вниз.

Систематическое применение одного и того же фильтра ко всему изображению – это хорошая идея. Если фильтр предназначен для обнаружения определенного типа признаков на входных данных, то систематическое применение этого фильтра на всем входном изображении дает ему возможность обнаружить этот признак в любой точке изображения. Эту возможность принято называть трансляционной инвариантностью, то есть общий интерес заключается в том, присутствует ли признак, а не в том, где он был обнаружен.

Результатом однократного умножения фильтра на входной массив является одно значение. Поскольку фильтр многократно применяется к входному массиву, результатом является двумерный массив выходных значений, которые представляют собой фильтрацию входных данных. Таким образом, двумерный выходной массив, полученный в результате этой операции, называется «картой признаков» (рис. 1) [7].

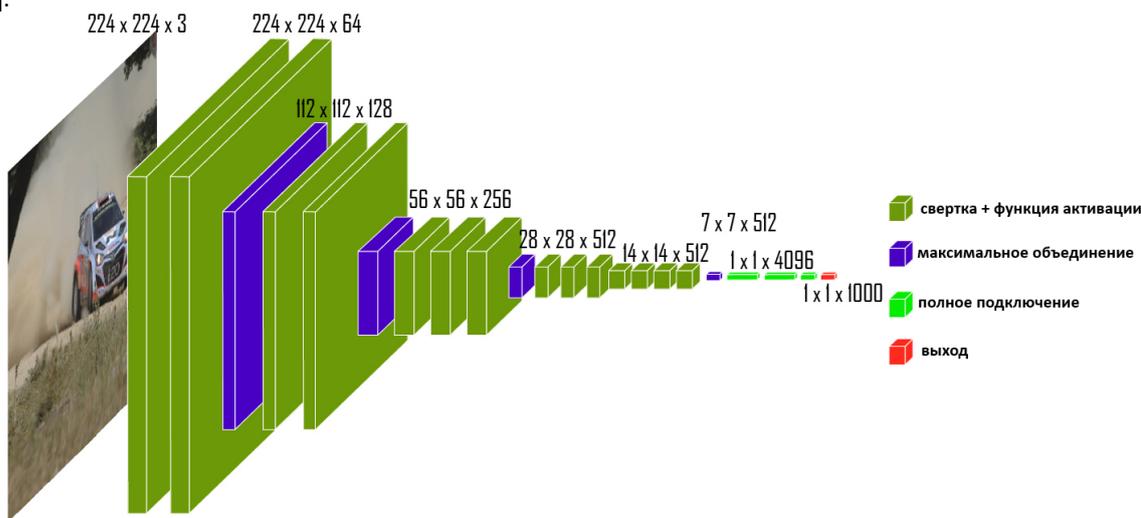


Рисунок 2 – Архитектура VGGFace

VGGFace известна своей простотой и эффективностью, а также способностью достигать высоких результатов в различных задачах компьютерного зрения, включая классификацию изображений и распознавание объектов. Архитектура модели представляет собой стек конволюционных слоев, за которыми следуют слои с максимальным объединением, с постепенным увеличением глубины. Такая конструкция позволяет модели обучаться сложным иерархическим представлениям визуальных признаков, что приводит к надежным и точным предсказаниям. Несмотря на свою простоту по сравнению с более современными архитектурами VGG остается популярным выбором для многих приложений глубокого обучения благодаря своей

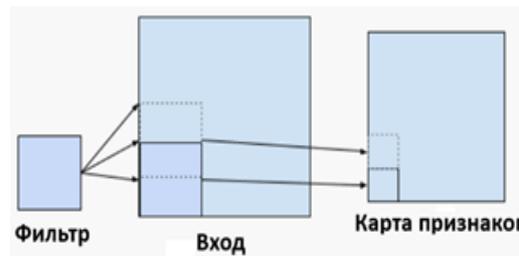


Рисунок 1 – Схема применения фильтра к двумерному входному изображению для создания карты признаков

Архитектура свёрточной нейронной сети модели VGGFace

Модель VGGFace – это архитектура свёрточной нейронной сети, предложенная группой Visual Geometry Group в Оксфордском университете [8]. Она отличается своей глубиной, состоящей из 16 слоев, включая 13 свёрточных и 3 полностью связанных слоя (рис. 2).

универсальности и отличной производительности.

Данная архитектура с функциями активации, приведенные на рисунке, обучалась и тестировалась на наборе данных ImageNet, который содержал 14 млн. изображений, относящихся к 1000 классам [8].

Видеоконтроль присутствия студентов на занятии с помощью компьютерного зрения

Схема видеорегистрации студентов при входе в аудиторию осуществляется в реальном времени. На рисунке 3 показана функциональная схема распознавания студентов по изображению лица из видеопотока.



Рисунок 3 – Схема видеорегистрации студентов при входе в аудиторию

При входе в аудиторию, камера, подключенная к компьютеру преподавателя, локализует лицо студента, в результате чего получается изображение локализованного лица. Далее данное изображение передается в блок формирования вектора признаков лиц свёрточной нейронной сетью VGGFace, которая выделенному лицу ставит в соответствие вектор признаков, взятый с базы данных лиц и анкет студентов. Процедура сравнения основывается на методе вычисления косинусного сходства вектора распознаваемого лица с каждым вектором-эталоном из базы данных по формуле 1:

$$\text{Сходство} = \frac{Y \cdot \bar{Y}}{\|Y\| \cdot \|\bar{Y}\|} = \frac{\sum_{i=1}^n y_i \bar{y}_i}{\sqrt{\sum_{i=1}^n y_i^2} \cdot \sqrt{\sum_{i=1}^n \bar{y}_i^2}}, \quad (1)$$

где Y и \bar{Y} – вектора признаков соответственно распознаваемого лица и лица-эталона из базы данных; $n = 2622$ (n – количество классов, т.е. распознаваемых лиц).

Для выработки признаков лица свёрточная нейронная сеть предварительно была обучена её создателями на примерах фотографий 2622-х человек (по 1000 фотографий на человека). Сеть настроена на классификацию распознаваемого лица, используя в качестве классов лица из обучающего множества. Поэтому результатом работы сети является 2622-мерный вектор, каждый элемент которого представляет собой вероятность сходства лица с одним из обучающего множества. Считается, что два изображения лица относятся к одному человеку, если они в одинаковой мере похожи на каждое лицо из обучающего множества. Для этого вектора признаков этих изображений в пространстве лиц из обучающего множества должны образовывать между собой достаточно острый угол [6, 9].

Распознаваемое лицо считается соответствующим эталону, если полученный коэффициент сходства выше определённого значения (в работе использовалось значение 0,7). После успешного сравнения лиц, происходит

запись в электронный журнал о явке студента на занятие.

Последовательная работа слоёв нейросети организована таким образом, чтобы осуществлялся переход от конкретных особенностей изображения к более абстрактным деталям, и далее к ещё более абстрактным. В этом процессе ключевую роль играет операция свёртки (см. форм. 2):

$$C_{i,j} = f\left(\sum_{k=1}^{m_y} \sum_{l=1}^{m_x} A_{i+k-1,j+l-1} B_{k,l}\right), \quad (2)$$

где A – матрица размером $(n_x \times n_y)$; B – матрица (ядро свёртки) размера $(m_x \times m_y)$;

C – результирующая матрица размера $[(n_x - m_x + 1) \times (n_y - m_y + 1)]$;

$i=1, 2, \dots, n_x - m_x + 1$; $j=1, 2, \dots, n_y - m_y + 1$;

$f()$ – функция активации.

Подвыборочный слой также как свёрточный имеет карты, но их количество совпадает с предыдущим (свёрточным) слоем. Его задача – уменьшить размерность карт предыдущего слоя. Для начала работы с системой требуется создать группу и анкету студента с фотографиями. Создание анкеты представлено на рисунке 4.

Рисунок 4 – Форма создания анкеты студента

Фотографию в анкету можно загрузить двумя способами: использовать подготовленное изображение, сделанное с фотоаппарата либо телефона; сделать фото с веб-камеры. Примеры загрузки изображений представлены на рисунках 5 и 6.

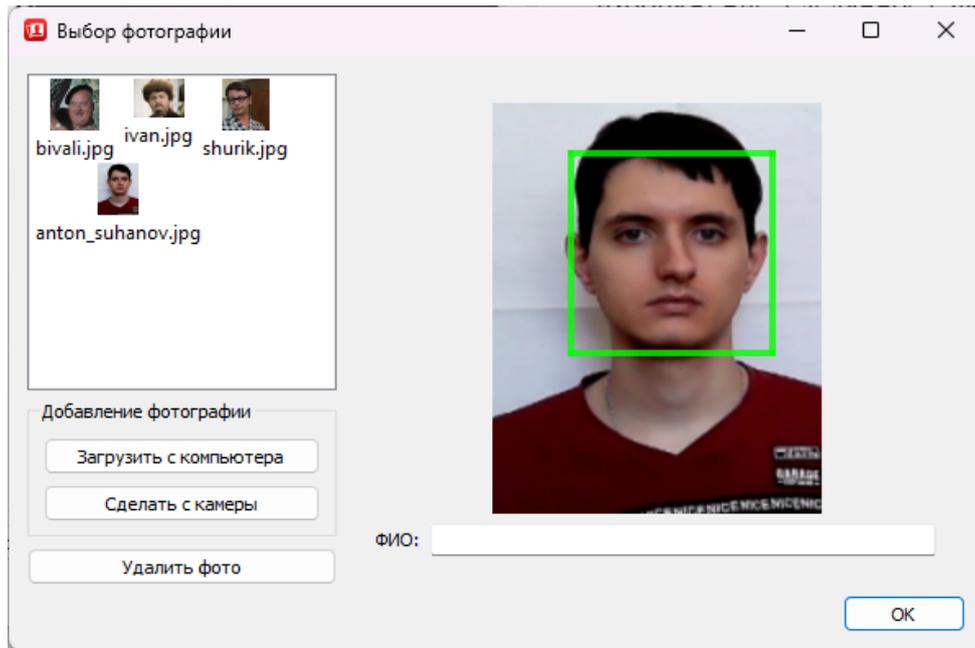


Рисунок 5 – Загрузка подготовленной фотографии

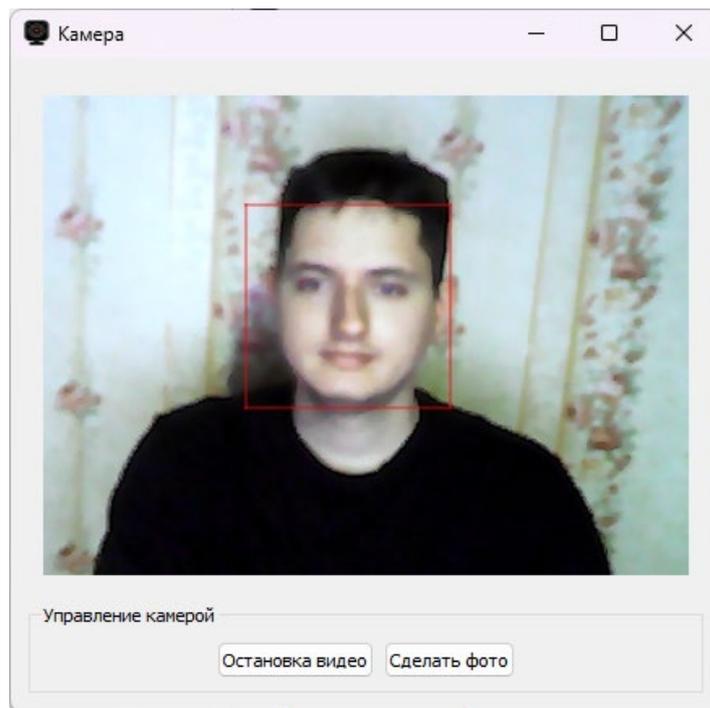


Рисунок 6 – Загрузка фото с камеры

После добавления анкет студентов и их фотографий в базу данных, на главной форме системы получим следующую таблицу, изображённую на рисунке 7.

Проведены эксперименты для оценки работы системы при предъявлении видеокамере фотографий лиц на бумажном носителе. Если выделенное лицо на изображении распознано, то в электронном журнале делается отметка о времени прибытия студента. Эксперименты

проводились на персональном компьютере со следующими техническими характеристиками:

- процессор: Intel Core i5-9400F CPU 2.90GHz;
- оперативная память: 16 ГБ;
- тип системы: 64-разрядная операционная система, процессор x64;
- видеокарта: NVIDIA GeForce RTX 4060 TI;
- система: Windows.

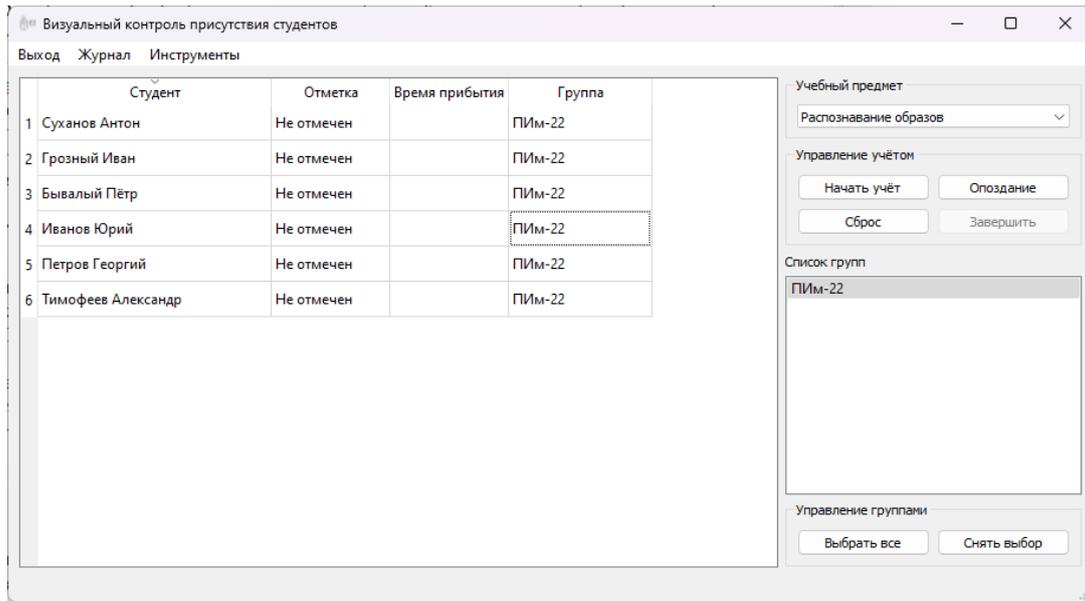


Рисунок 7 – Главная форма системы

Технические характеристики веб-камеры:

- разрешение в pix: 640*480;
- тип матрицы: CMOS;
- фокусное расстояние: 2,8 мм.;
- частота кадров: до 30 кадров/секунду

при разрешении в 640*480.

Выбрав группу для контроля и нажав на кнопку «Начать учёт», система начнёт видеорегистрацию студентов. Результат распознавания студентов с отметкой времени прибытия представлен на рисунке 8.

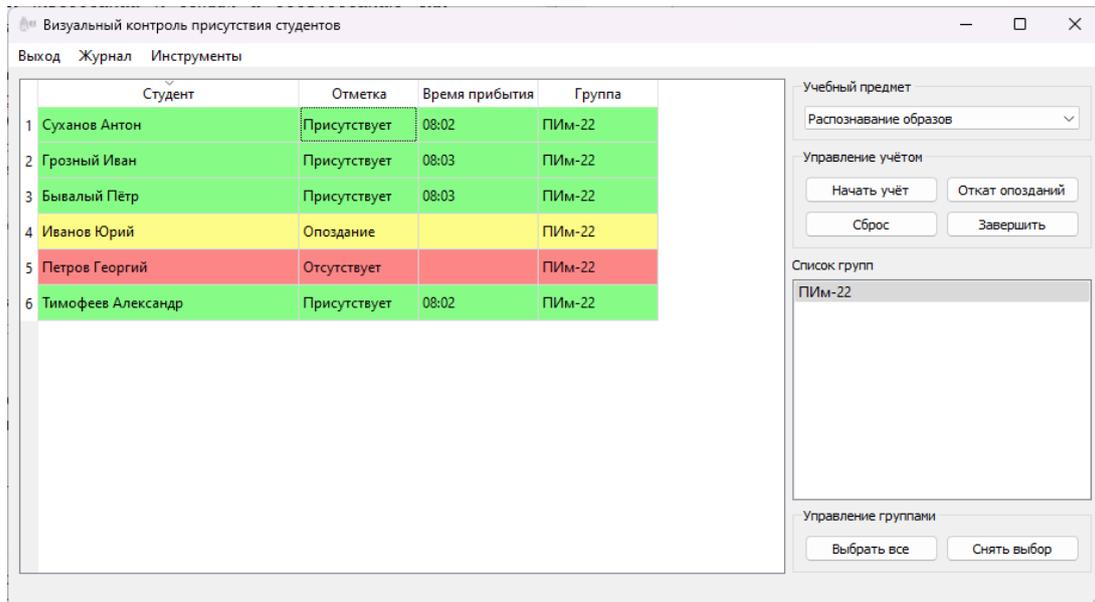


Рисунок 8 – Результат учета студентов

Как видно из результатов работы программы, изображенных на рисунке 8, программа успешно справилась с экспериментами.

Выводы

В данной статье представлена и описана архитектура свёрточной нейронной сети VGGFace. Разработана схема компьютерного

распознавания человека по его лицу. Расширен функционал системы регистрации студентов, позволяющий формировать видеобазу студентов по фотографиям, вводимых из фалов и видеокамеры.

Проведены эксперименты по распознавания студентов с автоматической отметкой в электронном журнале на небольшом объёме видео данных. При переходе обучения в режим оффлайн система будет тестироваться в

реальных условиях присутствия студентов группы (потока) в аудитории. Внедрение системы позволит расширить возможности виртуальной кафедры [10].

Литература

1. Федяев О.И., Бакаленко В.С. Интеллектуальная система принятия решений в отделении медицинского учреждения на основе нейросетевых, продукционных и статистических моделей. *Статистика и Экономика*. 2019;16(3):70-77. <https://doi.org/10.21686/2500-3925-2019-3-70-77>
2. Дворяткина, С. Н. Интеграция фрактальных и нейросетевых технологий в педагогическом контроле и оценке знаний обучаемых / С. Н. Дворяткина // Вестник РУДН. Серия : Психология и педагогика. - 2016. - Том 14. - № 4. – С. 451-465.
3. Федяев, О. И. Прогнозирование остаточных знаний студентов по отдельным дисциплинам с помощью нейронных сетей / О. И. Федяев // Известия ЮФУ. Технические науки. – 2016. – С. 122-136.
4. AI в обучении: на что способны технологии уже сейчас? // EduTech. - 2022. - № 4 [49]. – 60 с.
5. Струнин, Д. А. Искусственный интеллект в сфере образования / Д. А. Струнин. — Текст : непосредственный // Молодой ученый. — 2023. — № 6 (453). — С. 15-16. — URL: <https://moluch.ru/archive/453/99921/>

6. Федяев О.И., Коломойцева И.А. Автоматическая регистрация присутствия студентов на учебном занятии с помощью компьютерного зрения // XXI Национальная конференция по искусственному интеллекту с международным участием КИИ-2023 (Смоленск, 16-20 октября 2023 г.). Труды конференции. В 2-х томах. Т.1. – Смоленск: Принт-Экспресс, 2023. – С. 294-303.

7. Machine Learning Mastery. Making Developers Awesome at Machine Learning [Электронный ресурс] / Интернет-ресурс. – Режим доступа URL: <https://machinelearningmastery.com/convolutional-layers-for-deep-learning-neural-networks/>. – Загл. с экрана.

8. GeeksforGeeks | A computer science portal for geeks. VGG-16 CNN model [Электронный ресурс] / Интернет-ресурс. – Режим доступа URL: <https://www.geeksforgeeks.org/vgg-16-cnn-model/>. – Загл. с экрана.

9. Blog. Great Learning. Introduction to VGG16 | What is VGG16? model [Электронный ресурс] / Интернет-ресурс. – Режим доступа URL: <https://www.mygreatlearning.com/blog/introduction-to-vgg16/#VGG%20-%20The%20Idea>. – Загл. с экрана

10. Федяев О.И., Жабская Т.Е. Проектирование виртуальной кафедры университета на основе многомодельного агентно-ориентированного подхода // Искусственный интеллект. – 2010. – № 3. – С. 679-686.

Суханов А.А., Баев Д.Э., Федяев О.И. Видеорегистрация присутствия студентов в аудитории на основе нейросетевого распознавания лиц. В данной статье описана архитектура свёрточной нейронной сети VGGFace, на основе которой разработана схема компьютерного распознавания человека по его лицу. Выполнена программная реализация системы, которая осуществляет автоматическое ведение электронного журнала группы. Проведены эксперименты по видеорегистрации студентов при входе в аудиторию с помощью компьютерного зрения.

Ключевые слова: свёрточная нейронная сеть, распознавание лиц, нейронная сеть VGGFace, компьютерное зрение, регистрация студентов.

Sukhanov A.A., Baev D.E., Fedyaev O.I. Video recording of students' presence in the classroom based on neural network facial recognition. This paper describes the architecture of the convolutional neural network VGGFace, on the basis of which the scheme of computer recognition of a person by his face is developed. The program realization of the system, which performs automatic maintenance of the electronic group journal, is performed. Experiments on video registration of students at the entrance to the classroom with the help of computer vision are carried out.

Keywords: convolutional neural network, face recognition, VGGFace neural network, computer vision, student registration.

Статья поступила в редакцию 12.06.2024
Рекомендована к публикации профессором Григорьевым А. В.

Рациональные подходы к внедрению цифровых двойников в водопроводно-канализационные хозяйства

В. Н. Штепа

д.т.н, доцент, Белорусский государственный технологический университет,
shtepa@belstu.by, OrcID: 0000-0002-2796-3144, SPIN-код: 2834-2138

Аннотация

Проанализированы основные недостатки функционирования существующих систем автоматизации водопроводно-канализационных хозяйств. Определено одним из наиболее перспективных направлений повышения эффективности соответствующих технологических процессов использование цифрового моделирования (концепты цифровых двойников). С учётом значительной стоимости создания таких продуктовых решений обоснованы и предложены концептуальные схемы их практического внедрения в рамках уже работающих SCADA и АСУТП с дополнением ресурсными базами знаний, лабораторными информационно-моделирующими системами и виртуальными физико-математическими моделями.

Введение

На данный момент в мировой практике существуют технико-технологические проблемы, затрудняющие осуществление эффективного управления и мониторинга водопроводно-канализационных хозяйств (ВКХ), как населённых пунктов, так и промышленных предприятий [1-5]. Они включают в себя следующие составляющие:

- отсутствие измерительных средств, работающих в сегментах сетей, прежде всего водоотведения, способных в оперативном режиме (приблизённо к реальному времени) и удалённо передавать данные о качестве водных растворов, выдерживать агрессивную среду, а также быть энергонезависимыми, то есть функционировать без подключения к источнику электрического питания;

- отсутствие программного обеспечения, способного оценивать и прогнозировать качество водных растворов в сегментах сети её транспортировки;

- единицы продуктовых решений способных адаптивно управлять сооружениями очистки и водоподготовки, адекватно рассчитывать варианты действий технологов при залповых поступлениях ксенобионтов, а также прогнозировать экологическое состояние природных водных ресурсов, в том числе после их очистки [6].

При этом комплексным недостатком, который снижает эффективность функционирования современных ИТ-продуктов автоматизации водопроводно-канализационных хозяйств, является отсутствие единой информационной среды, которая бы позволила оптимизировать деятельность технических средств и кадровых ресурсов для гарантированного достижения нормативных требований к качеству водоснабжения и водоотведения при минимизации материальных и

других затрат [7]. Соответственно, обоснование информационно-моделирующего и управляющего программного обеспечения, нацеленного на преодоление составляющих такой научно-практической проблематики, можно характеризовать актуальной задачей.

Анализ существующих решений и требований к внедрению цифровых двойников

Один из современных подходов, с помощью которого достигается значительное повышение уровня автоматизации, что можно использовать и в ВКХ – цифровизация технологических процессов с синтезом цифровых двойников (ЦД) [8]. Перспективность внедрения последних продиктована тем, что область цифрового моделирования растёт быстрыми темпами. Так согласно анализа агентства MarketsandMarkets, в 2023 году объём рынка ЦД превысил \$10 млрд.; прогнозируется его увеличение в среднем на 61,3% в год и через 5 лет ожидается порядка \$100 млрд.

Нормативная база, обеспечивающая их внедрение [9]:

- ГОСТ Р – создан на семействе стандартов СССР и функционирует в СНГ;

- Международный стандарт ISO (International Organization for Standardization) – создан по инициативе Международной организации по стандартизации, на данный момент к нему присоединилось свыше 170 участников.

При этом мировой стандарт более детально проработан и адаптирован к практическому использованию [10]. В ISO 23247 «Automation systems and integration – Digital twin framework for manufacturing» ЦД определяется «цифровой моделью конкретного физического элемента или процесса с

подключениями к данным, которая обеспечивает конвергенцию между физическим и виртуальным состояниями с соответствующей скоростью синхронизации». В практическом контексте внедрение на объектах таких виртуальных моделей требует очень значительных финансово-материальных затрат для формирования информационной инфраструктуры и специализированное программное обеспечение (ПО) [8]. Таким образом необходимо создавать концептуальные модели ЦД, где бы минимизировались новые вложения, при этом использовался уже работающий информационный базис – выполнялось «неразрушающее внедрение»:

1. Сохранение работоспособности существующих систем;
2. Объединение разнотипных технических платформ;
3. Множественное подключение и одновременное использование;
4. Загрузка базы объектов работающих хранилищ данных;
5. Быстрое разворачивание системы;
6. Невысокие финансовые, временные и кадровые вложения.

При этом важно реализовать полную и достаточную управленческую иерархию [11] (рис. 1).

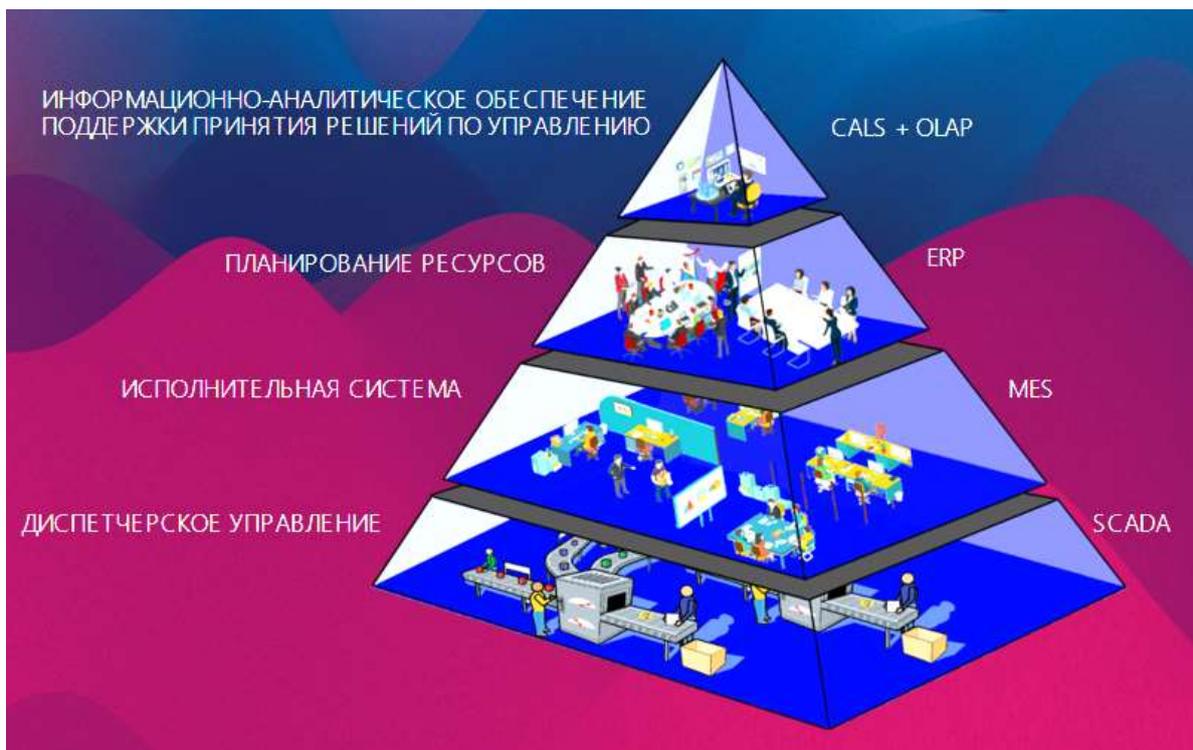


Рисунок 1 – Иерархическая архитектура построения информационно-управляющих систем промышленно-коммунальными объектами (SCADA (supervisory control and data acquisition) – диспетчерское управление; MES (Manufacturing Execution Systems) – производственное исполнение (или система управления технологией); ERP (Enterprise Resources Planning) – планирование ресурсов предприятия, обеспечивает финансово-хозяйственную деятельность, планирование и учет производства; OLAP (Online Analytical Processing) – аналитическая обработка информации в реальном времени; CALS-технологии (Continuous Acquisition and Life cycle Support) – информационные технологии, используемые в управлении процессами жизненного цикла изделия или системы)

Концептуальные схемы создания цифровых двойников ВКХ на основе SCADA, лабораторных информационно-моделирующих систем и автоматизированных систем управления технологическими процессами

Один из вариантов концептуальной схемы развёртывания ЦД на базе функционирующей на ВКХ SCADA представлен на рисунке 2, куда для дополнения измерительного информационного поля

интегрирована лабораторная информационно-моделирующая система (ЛИМС).

В рамках такого решения SCADA выполняет типовые для себя задачи обеспечения работ в реальном времени по сбору, обработке, отображению и архивированию информации об объекте или управление им. На данный момент диспетчерское управление является основным методом автоматизации ВКХ. При этом программное обеспечение устанавливается на компьютеры и контроллеры и, для связи с объектом, использует драйверы ввода-вывода и/или OPC/DDE серверы.

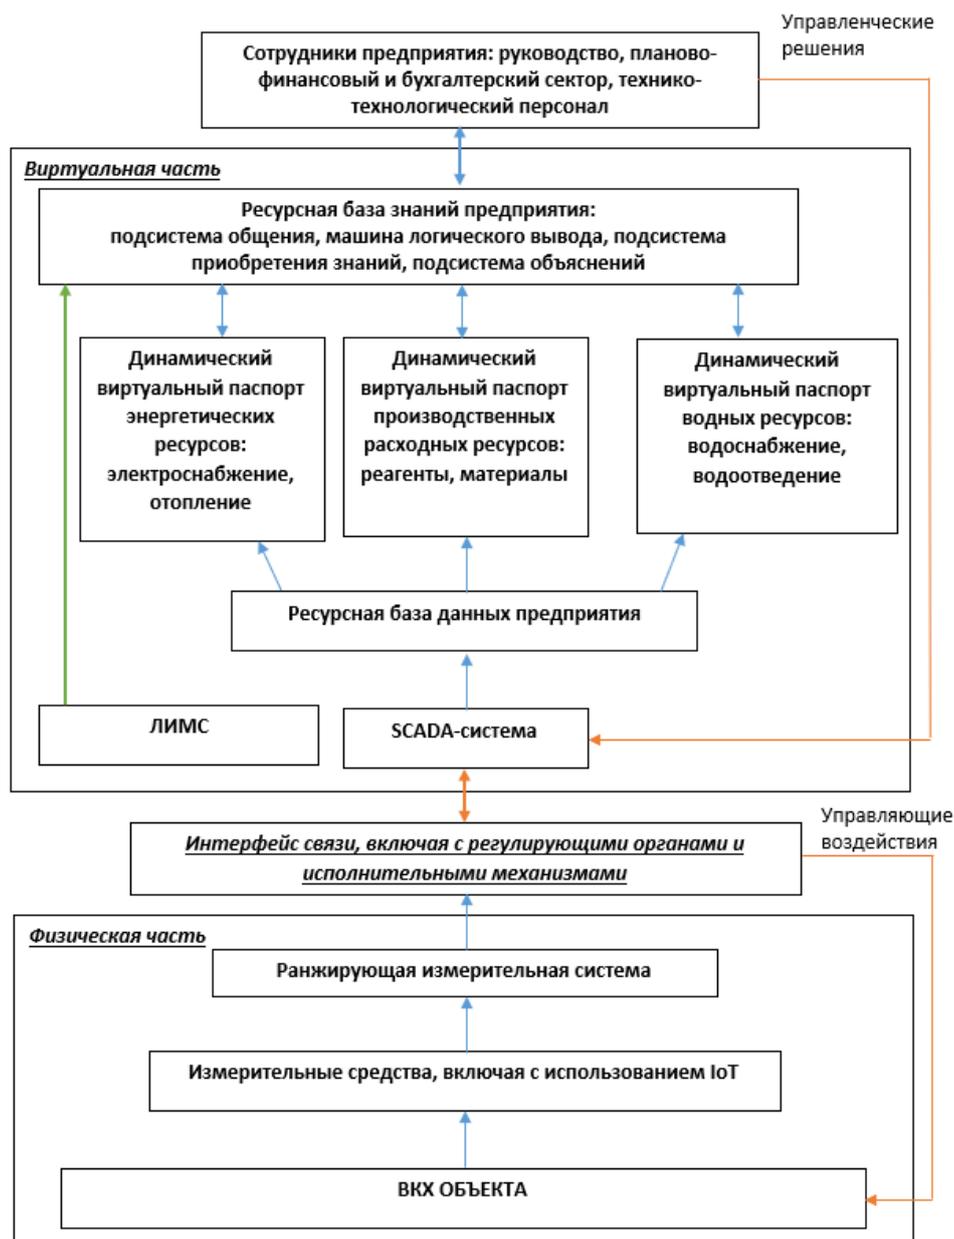


Рисунок 2 – Концептуальная схема создания цифрового двойника водопроводно-канализационного хозяйства с использованием функционирующей SCADA и интеграцией ЛИМС

Предлагаемая схема (см. рис. 2) позволяет поэтапно создавать функциональные и востребованные специалистами предприятий продуктовые решения, которые пошагово трансформируются в ЦД:

1. Настройка над SCADA ресурсной базы данных (визуализация информации) – с интеграцией информационных потоков от разрозненных SCADA в единый информационно-технологический канал;

2. Формирование на основе ресурсной базы данных динамических виртуальных паспортов технологических процессов (энергетического, производственно расходного, водного) [12] и обеспечение единой аналитической обработки ранее децентрализованной информации;

3. Преобразование виртуальных паспортов в ресурсную базу знаний;

4. Принятие управленческих решений на основе взаимодействия с ресурсной базой знаний и их выполнение через инфраструктуру и функционал SCADA.

Для увеличения полноты базы данных (базы знаний) в лабораториях ВКХ необходимо создать специализированные ЛИМС – это технология, предназначенная для получения достоверной информации по результатам испытаний (исследований) и оптимизации управления этой информацией с целью ее использования для принятия корректных своевременных управленческих решений.

Другим ИТ-продуктом, который улучшит качество передаваемой в базу данных (базу знаний) технологических параметров и уменьшит «шумовую» составляющую, выступит ранжирующая

измерительная система. Для неё результат измерения величины попадает в одну из категорий и число таких категорий конечно [10]. Можно выделить два основных типа ранжирующих измерительных систем: системы, в которых измерения проводит человек (контролер) при помощи своих органов чувств; и автоматические системы, в которых задачу ранжирования осуществляет электронный прибор (в

нашем случае программируемый контроллер) – они могут работать без участия человека-контролера.

Поскольку SCADA по своему базовому предназначению изначально является частью автоматизированных систем управления технологическими процессами (АСУ ТП), то обосновано её функционально расширить до последней (рис. 3), если она уже не используется.

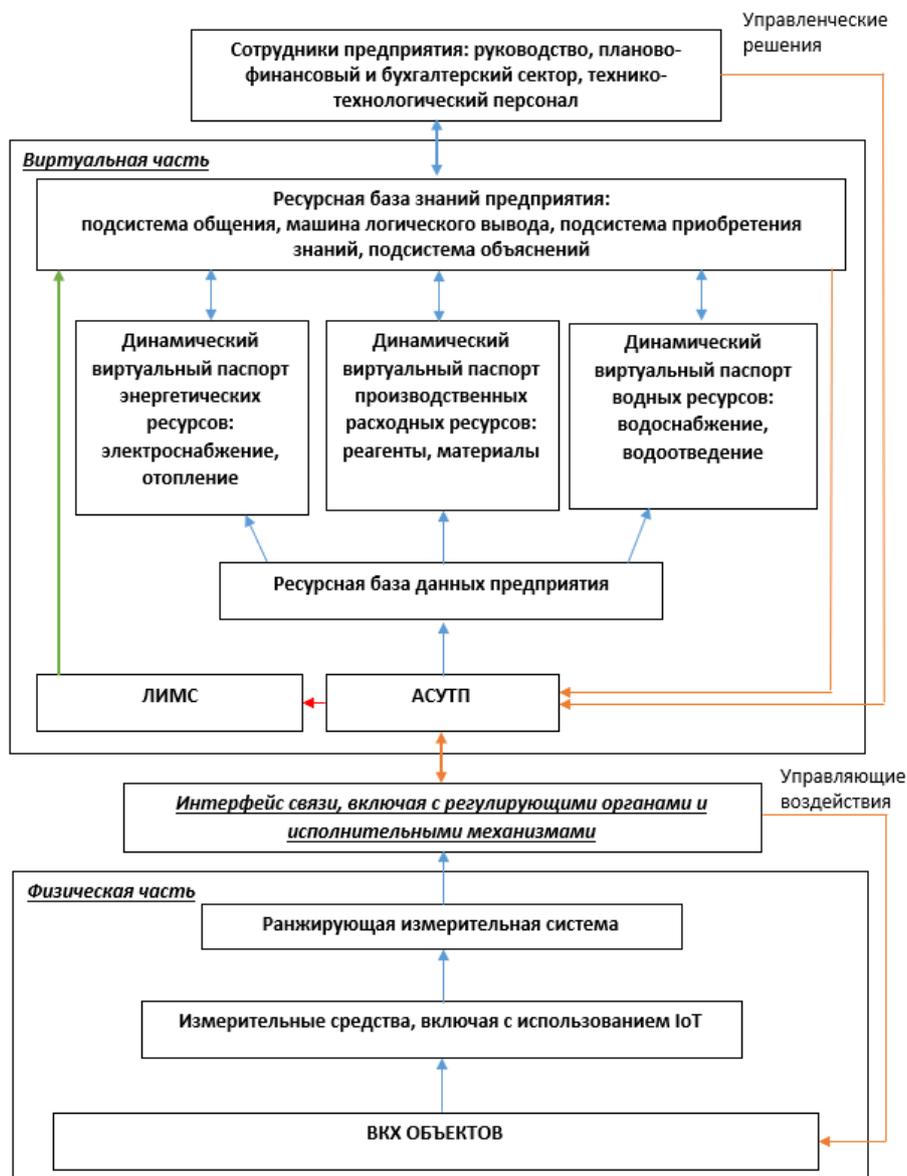


Рисунок 3 – Концептуальная схема создания цифрового двойника водопроводно-канализационного хозяйства с использованием АСУТП и интеграцией ЛИМС

Таким образом (см. рис. 3) будет реализовано построение автоматизированной системы управления (а не только диспетчеризации), которая соответствует иерархии рисунка 1. Внедрение вместо SCADA АСУТП позволит решить намного больший спектр задач на объектах ВКХ:

- Автоматизация процессов с максимально допустимой производительностью;

- Управление с учетом плана и задач путем оперативной перенастройки параметров технологического оборудования;

- Реализация статистического управления в реальном времени, например, за экстремальными и адаптивными алгоритмами;

- Оптимизация технологических процессов в режиме реального времени.

Концептуальная схема создания цифровых двойников ВКХ с использованием физико-математических моделей и их интеграцией с АСУТП

С учётом того, что на данный момент имеет место критическая недостаточность измерительных средств качества водных растворов способных работать в режиме реального времени в промышленных условиях ВКХ (согласно авторской экспертной оценки недостаточность номенклатуры такого измерительного оборудования – около 70-75%); также значительно не хватает аккредитованных лабораторий – возникают очень значительные опасности как для потребителей водных ресурсов (населённые пункты, предприятия), так и для геоэкосистем, в которые сбрасываются сточные воды, особенно в условиях потенциального

возникновения чрезвычайных ситуаций антропогенного и/или природного происхождения [13]. Тогда для он-лайн оценки эколого-энергетической эффективности параметров водоснабжения и/или водоотведения (включая очистные сооружения и станции водоподготовки) целесообразно использовать автоматизированные компьютерно-интегрированные физико-математические модели технологических процессов с включением их в АСУТП и локализацией непосредственно на объектах ВКХ (рис. 4). Для таких целей разработано и апробировано методическое обеспечение проектирования физической модели (ФМ) водообработки, в данном случаи на примере очистки сточных вод (рис. 5), как составляющей развития (усовершенствования) информационно-измерительных систем в двух аспектах: структурном и функциональном [14].

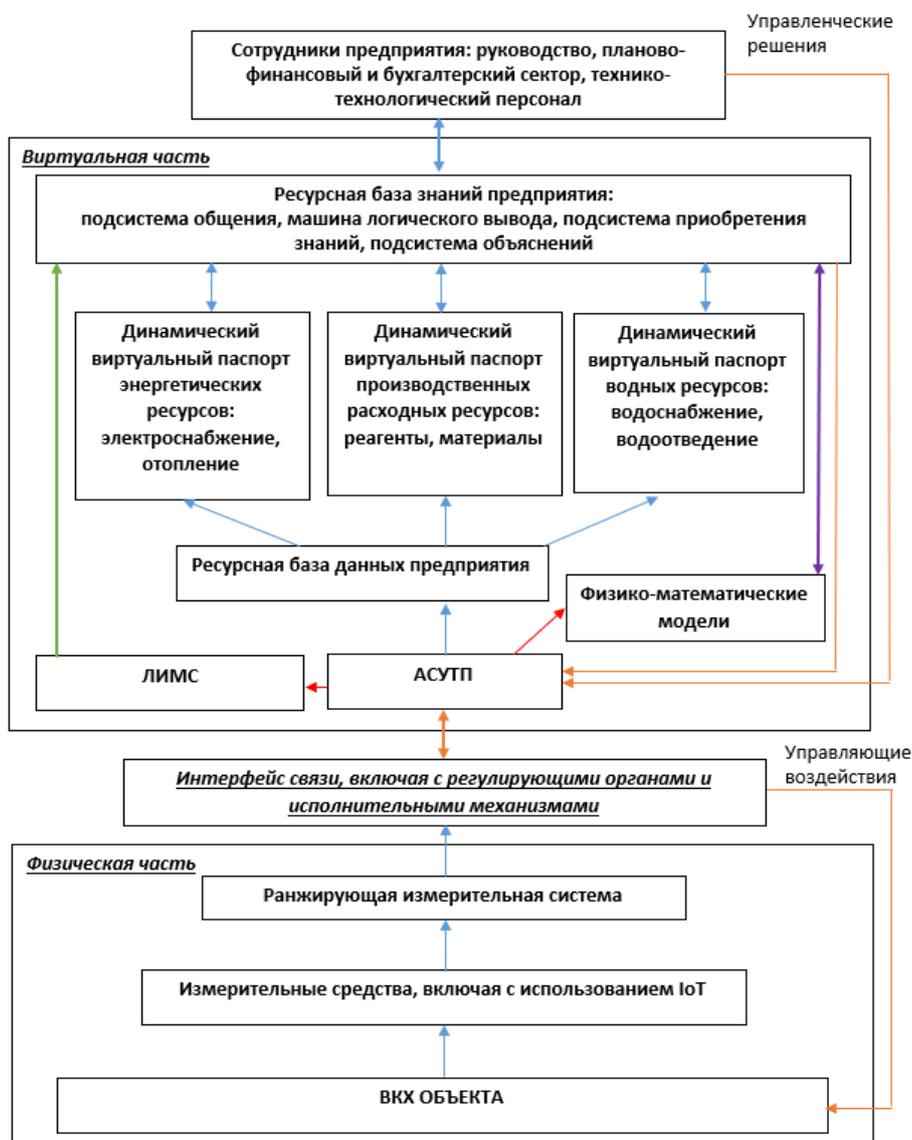


Рисунок 4 – Концептуальная схема создания цифрового двойника водопроводно-канализационного хозяйства с использованием функционирующей АСУТП интеграцией ЛИМС и автоматизированных физико-математических

моделей



Рисунок 5 – Схема использования виртуальной физико-математической модели при поддержке управления очисткой сточных вод

Расширив функциональные возможности ФМ и дополнив ее программной реализацией методического обеспечения, которое реализует воспроизведения и/или сохранение показателей водных растворов на этапах проектирования и при эксплуатации в режиме реального времени, аргументировано виртуальную меру энергоэффективности водоочистки (см. рис. 5) использовать в цифровом двойнике ВКХ (см. рис. 4).

Заключение

Промышленное применение цифровых двойников в рамках объектов ВКХ обосновано реализовывать на базе работающих на предприятиях SCADA, с подключением к ним ЛИМС, и дальнейшей трансформацией до АСУТП (интегрирую физико-математические модели, например, класса виртуальных рабочих мер) и общепроизводственных цифровых моделей с внедрением информационно-аналитических платформ.

Такой подход при рационализации материально-финансовых затрат и гибкости переобучения персонала позволит поддерживать: эффективное управление объектами водоснабжения и водоотведения, включая оценку качества сточных вод; повышать ресурсо- и энергоэффективность технологических процессов; обеспечивать экологическую безопасность систем водоснабжения и водоотведения, включая оптимизацию функционирования очистных сооружений; более качественно планировать операции и выполнять работ по техническому обслуживанию и ремонту; оценку рисков и раннее предупреждение потенциальных чрезвычайных ситуаций техногенного характера и недопущение их возникновения, например, в случае попадания опасных токсикантов на биологические очистные сооружения; адекватное формирование технических заданий на строительство, реконструкцию или модернизацию.

Дальнейшие исследования целесообразно нацелить на построение методологии синтеза цифровых платформ организаций ВКХ, как сложных многопараметрических объектов с биотехнологическими подсистемами.

Благодарность. Работа выполнена при финансовой поддержке БРФФИ (договор № Ф23У-012 от 02.05.2023 года).

Литература

- Архипов Д.Э., Едемский К.Е., Кожевникова С.И., Дмитриев В.В. Развитие мониторинга водных объектов на основе интегральной оценки экологического статуса и моделирования экологических функций // *European Journal of Natural History*. – 2022. – № 2. – С. 31-37
- Directive 2000/60/EC of the European Parliament and of the Council of 23 October 2000 establishing a framework for Community action in the field of water policy. *Official Journal L 327*, 22/12/2000, 73 p.
- Eugenio Molina-Navarro, Pedro Segurado, Paulo Branco, Carina Almeida, Hans E. Andersen Predicting the ecological status of rivers and streams under different climatic and socioeconomic scenarios using Bayesian Belief Networks. *Limnologia* 80 (2020) 125742 <https://doi.org/10.1016/j.limno.2019.125742>.
- Hering, D., Carvalho, L., Argillier, C., Beklioglu, M., Borja, A., Cardoso, A.C., et al., 2015. Managing aquatic ecosystems and water resources under multiple stress — an introduction to the MARS project. *Sci. Total Environ.* 503–504, pp. 10–21.
- Алексеев, Е. В. Основы моделирования систем водоснабжения и водоотведения : учебное пособие / Е. В. Алексеев, В. Б. Викулина, П. Д. Викулин - Москва : Издательство МИСИ - МГСУ, 2017. - 126 с. - ISBN 978-5-7264-1641-0. - Текст: электронный // ЭБС Консультант студента: [сайт]. - URL:<https://www.studentlibrary.ru/book/ISBN9785726416410.html> (дата обращения: 23.09.2022).

6. Штепа, В. Н. Концептуальные основы энергоэффективной системы управления комбинированными системами водоочистки / В. Н. Штепа // Известия высших учебных заведений и энергетических объединений СНГ. Энергетика: научно-технический журнал. – 2016. – № 5. – С. 479 – 487.

7. Штепа, В.Н. Интеллектуальная система анализа и прогноза экологической безопасности биологических сооружений очистки сточных вод / В.Н. Штепа, Н.Ю. Золотых // Первая выставка-форум IT-академграда «Искусственный интеллект в Беларуси»: сборник докладов, Минск, 13-14 октября 2022 г. / Объединенный институт проблем информатики Национальной академии наук Беларуси. - Минск: ОИПИ НАН Беларуси, 2022. - С. 41-45.

8. Обоснование структуры и состава систем водоочистки на основе оценки уровня автоматизации технологических процессов / В.Н. Штепа [и др.] // Вестник Брестского государственного технического университета. - 2020. - № 4. - С. 17-22.

9. Штепа, В.Н. Структура и функционал интеллектуальной системы поддержки принятий решений в водоотведении / В.Н. Штепа // Информатика и кибернетика: научный журнал. - 2022. - №3 (29). - С.51-57.

10. Штепа, В.Н. Обоснование и схемы использования ранжирующих измерительных систем экологического мониторинга и интеллектуального анализа режимов водоотведения / В.Н. Штепа, Н.Ю. Золотых, С.Ю. Киреев // Вестник Полоцкого

государственного университета. Серия Ф. Строительство. Прикладные науки: научный журнал. - 2023. - № 1. - С. 94-103.

11. В.В. Бураков, Н.Г. Мустафин, М.Ю. Охтилев, Б.В. Соколов. Методология и технологии решения задач проактивного мониторинга и управления сложными техническими объектами // Перспективные направления развития отечественных информационных технологий: материалы V межрегиональной научно-практической конф. Севастополь, 24-28 сентября 2019 г. / Севастопольский государственный университет; науч. ред. Б.В. Соколов. – Севастополь: СевГУ, 2019. С.112–114.

12. Штепа, В.Н. Функционально-статический анализ системы контроля водоотведения и оценка подходов к её цифровому моделированию / В.Н. Штепа // Информатика и кибернетика: научный журнал. – 2023. – № 3 (33). – С. 35-42.

13. Войтов И. В., Штепа В. Н., Смелов В. В., Карпович Д. С. Оценка степени автоматизации и внедрения цифровых платформ управления системами водоотведения // Труды БГТУ. Сер. 3, Физико-математические науки и информатика. 2024. № 2 (284). С. 43–52

14. Иванов С.А., Никольская К.Ю., Радченко Г.И., Соколинский Л.Б., Цымблер М.Л. Концепция построения цифрового двойника города // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. 2020. Т. 9, № 4. С. 5–23. DOI: 10.14529/cmse200401.

Штепа В.Н. Рациональные подходы к внедрению цифровых двойников в водопроводно-канализационные хозяйства. Проанализированы основные недостатки функционирования существующих систем автоматизации водопроводно-канализационных хозяйств. Определено одним из наиболее перспективных направлений повышения эффективности соответствующих технологических процессов использование цифрового моделирования (концепты цифровых двойников). С учётом значительной стоимости создания таких продуктовых решений обоснованы и предложены концептуальные схемы их практического внедрения в рамках уже работающих SCADA и АСУТП с дополнением ресурсными базами знаний, лабораторными информационно-моделирующими системами и виртуальными физико-математическими моделями.

Ключевые слова: водоотведение, водоснабжение, водопроводно-канализационные хозяйства, управление, цифровое моделирование, цифровой двойник.

Shtepa V.N. Rational approaches to the implementation digital twins in water supply and sewerage systems. The main shortcomings existing automation systems for water supply and sewerage facilities are analyzed. One of the most promising results increasing the efficiency technological processes using conceptual analysis (the concept of digital twins) is determined. Taking into account the cost of creating products such solutions, conceptual schemes for their practical application within the framework of the already industrial SCADA and automated process control systems with additions resource knowledge bases, laboratory information-modeling mechanisms and virtual physical and mathematical ones are substantiated and proposed.

Keywords: water disposal, water supply, water supply and sewerage, management, digital modeling, digital twin.

Статья поступила в редакцию 10.10.2024
Рекомендована к публикации профессором Мальчевой Р. В.

Интеллектуальная система для оценки тремора у пациентов с диагностированной болезнью Паркинсона

А. Д. Камбалина

ФГБОУ ВО «Томский национальный политехнический университет»
инженерная школа информационных систем и робототехники
E-mail: adk43@tpu.ru

Аннотация:

В статье рассматривается применение методов машинного обучения для диагностики болезни Паркинсона. Определены методы машинного обучения подходящие для решения задачи классификации. Разработано программное обеспечение, выполняющее определение упражнения для оценки тремора. Для классификации видеозаписей по наименованию упражнения использовались модели нейронной сети, логистической регрессии, классификатор XGBoost, случайных лесов, опорных векторов. Лучшие результаты машинного обучения были получены с помощью классификатора случайного леса.

Общая постановка проблемы

Одним из наиболее распространенных неврологических заболеваний в пожилом возрасте является болезнь Паркинсона с распространённостью до 2205 случаев на 100 тыс. человек у лиц старше 85 лет. В настоящее время в мире насчитывается более 5–6 млн. пациентов, а в России болезнь Паркинсона выявлена у 210 тыс. человек [1].

Болезнь Паркинсона (БП) – это мультисистемное нейродегенеративное заболевание, при котором развиваются моторные и немоторные нарушения, приводящие к социальной, бытовой и профессиональной дезадаптации, снижению повседневной активности и качества жизни [2]. Болезнь характеризуется наличием тремора покоя, скованности, замедлением и уменьшением движений, нарушением походки и постуральной нестабильностью.

Своевременная постановка правильного диагноза позволяет принять меры для замедления прогрессирования заболевания, назначить противопаркинсоническую терапию, снизить негативное влияние болезни на качество жизни пациента и его окружение [3]. Для достижения наилучших результатов вести пациентов с диагностированной БП должен квалифицированный невролог, имеющий опыт диагностики и лечения как моторных, так и немоторных проявлений заболевания. Зачастую на раннем этапе развития болезни пожилые люди в связи с нехваткой кадров в больнице или населенном пункте обследуются врачами общей практики, которые не имеют достаточной квалификации [4].

Исследования

С развитием информационных технологий широкое распространение получает телемедицина и создание цифровых двойников. Современное программное обеспечение позволяет выполнить диагностику различных заболеваний с помощью искусственного интеллекта (ИИ).

Применение данных технологий позволяет улучшить систему здравоохранения: повысить качество предоставляемых услуг при одновременном снижении расходов на обследования для медицинских учреждений [5]. Если разработана методика регистрации и перевода в цифровой вид физиологических сигналов (ЭКГ, концентрация компонентов крови, определение характерных точек и т.п.), то к полученным данным широко применяются алгоритмы машинного обучения.

Для диагностики БП могут использоваться различные методики: оценка состояния крови, анализ почерка пациента, голосовых маркеров, оценка данных с датчиков акселерометра и гироскопа, записей ЭЭГ и видеозаписей пациентов [6].

Нерешенные проблемы

Данная статья посвящена оценке тремора – наиболее характерного симптома болезни Паркинсона. Тремор (дрожательный гиперкинез) – это непроизвольные, ритмичные, колебательные движения части тела, обусловленные поочередными или одновременными сокращениями мышц агонистов и антагонистов [7]. Возникновение тремора связано с нарушением контролирующих

связей мозжечка и несвоевременной работой мышц-антагонистов при выполнении различных движений.

По наличию движения выделяют тремор покоя и тремор действия: кинетический, постуральный, изометрический и кинезиоспецифический.

Постуральный тремор возникает при длительном удержании статичного положения, например, разведенные в стороны или вытянутые вперед руки. Кинетический тремор возникает при произвольном движении.

Тремор делится на физиологический и патологический. Физиологический тремор (низкоамплитудное дрожание) имеет частоту от 8 до 12 Гц и его можно выявить у любого здорового человека. Патологический тремор имеет большую амплитуду, более низкую частоту. Он ограничивает повседневную активность пациента и виден невооруженным глазом.

Классический вариант паркинсонического тремора (ПТ) представляет собой тремор покоя, возникающий при полном расслаблении мышц с типичной частотой 3–6 Гц. Вовлекает чаще руки, иногда ноги, подбородок, губы, но исключительно редко – голову [7].

Несмотря на распространенность тремора в клинической практике, определить относится патологический тремор к болезни Паркинсона или другому неврологическому заболеванию всё еще представляет собой сложную задачу. Поэтому остро стоит вопрос диагностики дрожательных гиперкинезов, позволяющий объективно оценить тремор.

Треморграфия – это инструментальный метод регистрации и количественной оценки тремора, который представляет особый интерес. Среди кинематических методов регистрации тремора выделяют гироскопию, системы видеорегистрации, фонотремометрию и т.д. [8].

Постановка цели и задач

Статья посвящена созданию инструмента для объективной, точной и, по возможности,

ранней диагностики болезни Паркинсона. Целью исследовательской работы является разработка программного обеспечения, выполняющего оценку постурального и кинетического тремора у пациентов с диагностированной болезнью Паркинсона.

Анализ видеозаписей с выполненными пациентами упражнений происходит с применением методов искусственного интеллекта, компьютерного зрения и машинного обучения. Анализ кинетического и постурального тремора на записи с видеокамеры является диагностическим методом, так как не требует дорогостоящего оборудования, но позволяет оценить наличие и степень тремора.

Точная диагностика болезни Паркинсона требует специализированного измерительного оборудования, гарантирующего высокое качество результатов измерений. Рекомендованное программным обеспечением посещение врача-невролога и проведение специальным образом организованного измерительного эксперимента, обеспечит получение достаточно полной и достоверной информации о наличии болезни Паркинсона [9].

Подготовка данных

Исходными данными для алгоритмов искусственного интеллекта стали:

1. результат анализа видеозаписей, содержащий позиции в трехмерном пространстве 21 характерной точки и временную отметку;

2. анкета пациента, содержащая пол, возраст, определенный врачом диагноз, статус пациента, название упражнения, выполняемого пациентом.

На рисунке 1 представлены характерные точки, которые используются для машинного обучения. Также произведена предварительная подготовка данных, в результате которой были удалены пропущенные значения, шумы, а также ошибочные значения в данных, полученных с видеокамеры. На рисунке 2 представлен пример исходного набора данных.



Рисунок 1 - Характерные точки, используемые для машинного обучения

	имя файла данных	Folder Path	пол	полных лет	пациент off/on	определенный диагноз врачом (0-5)
0	raw_data_d786d645-db38-11ec-b494-e82aea2c97f4.csv	кинетический тремор	мужской	52	off	1
1	raw_data_bdcba44f-0d6a-11ed-8857-b6da2cf29e9d.csv	Постуральный тремор	мужской	78	on	0
2	raw_data_750c0f09-b09a-11ec-9699-58a023d3f6d9.csv	Постуральный тремор	мужской	71	on	0
3	raw_data_d90846c3-3969-11ed-a96d-b469216ca443.csv	кулак	мужской	23	off	1
4	raw_data_c27fbeb3-1882-11ed-95c1-b469216ca443.csv	кинетический тремор	мужской	23	off	2

Рисунок 2 – Исходный набор данных

Разработка программного обеспечения

Для создания программного обеспечения используется объектно-ориентированный язык программирования Python, имеющий широкий набор библиотек для машинного обучения. Среда разработки PyCharm позволяет установить необходимую для разработки графического интерфейса библиотеку Tkinter, библиотеку для анализа характерных точек MediaPipe, а также библиотеки для анализа данных Tensorflow, Keras, Numpy, Seaborn и т.д. При запуске приложения пользователю доступны видеoinструкции с возможными

упражнениями, советы по использованию приложения. В разработанном программном обеспечении (ПО) предусмотрена регистрация, вход пользователя в личный кабинет, в котором хранится анкета, сохраненные пользователем видеозаписи, а также результаты машинного обучения. Пользователь программного обеспечения может настроить камеру, подключенную к устройству и записать выполнение упражнения, либо загрузить видеозапись с файловой системы компьютера.

Разработанный графический интерфейс приложения представлен на рисунке 3.

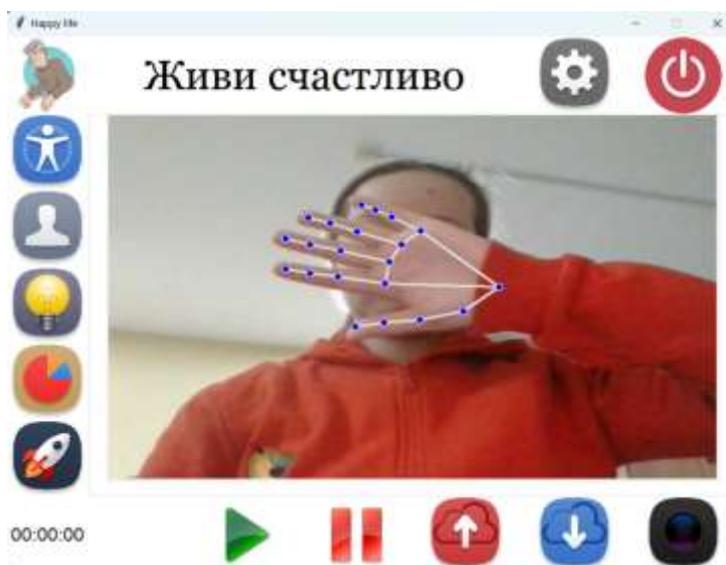


Рисунок 3 – Графический интерфейс приложения

Применение искусственного интеллекта

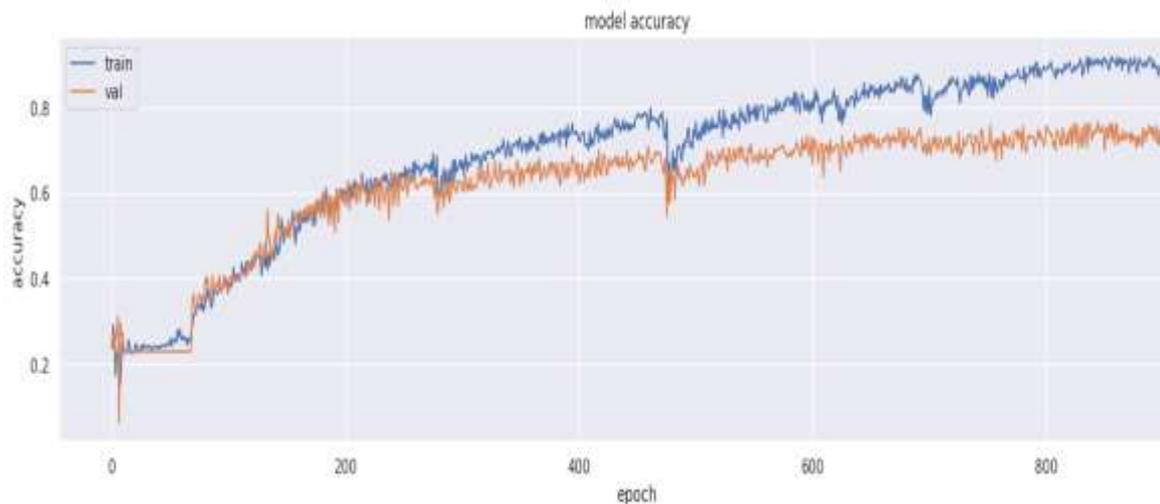
Использование экспертных систем для решения задачи классификации тремора позволяет улучшить диагностику, осуществлять прогноз и проводить дальнейшее эффективное лечение у врача-невролога. Для выявления ранних признаков болезни Паркинсона

происходит оценка видеозаписей на наличие тремора, который возникает у пациента при выполнении одного из 5 упражнений: «Постуральный тремор», «Кулак», «Постукивание пальцами», «Кинетический тремор», «Пронация и супинация кисти».

Для классификации использовались модели нейронной сети, логистической регрессии, классификатор XGBoost, случайных

лесов, опорных векторов и т.п. Исходный датасет для машинного обучения был разбит на тренировочный и тестовый датасеты по 834 и 358 видеозаписей, длиной от 100 до 1000

секунд. Лучшие результаты машинного обучения были получены с помощью классификатора случайного леса.



```
model = tf.keras.models.Sequential([
    tf.keras.layers.Input((21 * 3 * 100 + 4, )),
    tf.keras.layers.Dropout(0.1),
    tf.keras.layers.Dense(2400, activation='relu'),
    tf.keras.layers.Dropout(0.1),
    tf.keras.layers.Dense(960, activation='relu'),
    tf.keras.layers.Dropout(0.1),
    tf.keras.layers.Dense(48, activation='relu'),
    tf.keras.layers.Dropout(0.1),
    tf.keras.layers.Dense(10, activation='relu'),
    tf.keras.layers.Dense(NUM_CLASSES, activation='softmax')
])
```

Рисунок 4 – Результаты и пример модели машинного обучения

Вывод

В ходе выполнения научно-исследовательской работы было разработано программное обеспечение, выполняющее оценку постурального и кинетического тремора у пациентов с диагностированной болезнью Паркинсона. Данное приложение может быть использовано пациентами с неврологическими заболеваниями, врачами в медицинских учреждениях, сотрудниками исследовательских научных центров.

Для классификации видеозаписей по наименованию упражнения использовались модели нейронной сети, логистической регрессии, классификатор XGBoost, случайных лесов, опорных векторов. Лучшие результаты машинного обучения были получены с помощью классификатора случайного леса.

Литература

1. Байрамукова, А.М. Эпидемиология болезни Паркинсона в различных странах мира

[Текст] / А.М. Байрамукова, А.К. Ажахметова, С.М. Карпов // Успехи современного естествознания. –2013. – № 9. - С. 20–21.

2. Клинические рекомендации. Болезнь Паркинсона, вторичный паркинсонизм и другие заболевания, проявляющиеся синдромом паркинсонизма [Электронный ресурс] / Интернет-ресурс. - URL: https://disuria.ru/_ld/12/1253_kr21G20G23MZ.pdf - Загл. с экрана.

3. Катунина Е.А. Подходы к ранней диагностике болезни Паркинсона [Текст] / Е.А. Катунина, Е.П. Ильина, Г.И. Садекова, Е.И. Гайсенюк // Журнал неврологии и психиатрии им. С.С. Корсакова, т. 119, № 6 –2019. – С. 119-127.

4. Бриль Е.В. Актуальность неврологической помощи в ведении пациентов с болезнью Паркинсона / [Текст] / Е.В. Бриль, Н.В. Федорова, Т.К. Кулуа, О.С. Зимнякова, М.А. Аникина // Фарматека, т. 9, №18 –2017. – С. 71–75.

5. Лихачев С. А. Трemor: феноменология и способы регистрации [Текст] / С. А. Лихачев, В. В. Ващилин, С. К. Дик // Медицинский журнал. - 2010. - № 2. - С. 133-137.

6. Пат. 2764568 Российская Федерация МПК G16H 50/00. Способ диагностики болезни Паркинсона на основе анализа видеоданных с применением машинного обучения [Электронный ресурс] / Сомов А.С., Дылов Д.В., Коваленко Е.А., Талицкий А.М., Аникина А.С., Щербак А.С.; Автономная некоммерческая образовательная организация высшего образования «Сколковский институт науки и технологий». – № 2021109243; заявл. 05.04.2021; опубл. 18.01.2022 – Электрон. версия печ. публ. – Доступ с сайта ФГУ ФИПС.

7. Jie Mei, Christian Desrosiers, Johannes Frasnelli Machine Learning for the Diagnosis of Parkinson's Disease: A Review of Literature [Electronic resource] / Интернет-ресурс. - Режим доступа: [www/ URL: https://www.frontiersin.org/articles/10.3389/fnagi.2021.633752/full](http://www.frontiersin.org/articles/10.3389/fnagi.2021.633752/full) - Загл. с экрана.

8. Говорова, Т. Г. Трemor: классификация, клиническая характеристика [Текст] / Т.Г. Говорова, А.А. Таппахов, Т.Е. Попова, У.Д. Антипина // Consilium Medicum, т. 20, № 9 –2018. – С. 95–100.

9. Говорова Т.Г. Трemorография в клинической практике [Текст] / Т.Г. Говорова, Т.Е. Попова, А.А. Таппахов // Нервно-мышечные болезни, т. 9, №4 –2019. – С. 61–72.

Камбалина А.Д. Интеллектуальная система для оценки пострурального и кинетического тремора у пациентов с диагностированной болезнью Паркинсона. В статье рассматривается применение методов машинного обучения для диагностики болезни Паркинсона. Определены методы машинного обучения подходящие для решения задачи классификации. Разработано программное обеспечение, выполняющее определение упражнения для оценки тремора. Для классификации видеозаписей по наименованию упражнения использовались модели нейронной сети, логистической регрессии, классификатор XGBoost, случайных лесов, опорных векторов. Лучшие результаты машинного обучения были получены с помощью классификатора случайного леса.

Ключевые слова: болезнь Паркинсона, трemor, машинное обучение, интеллектуальная система, разработка, программное обеспечение.

Kambalina A.D. The intelligent system for assessing postural and kinetic tremor in patients diagnosed Parkinson's disease. The article discusses the application of machine learning methods for the diagnosis of Parkinson's disease. Machine learning methods suitable for solving the classification problem are identified. Software is developed to perform movement detection for tremor assessment. Neural network models, logistic regression, XGBoost classifier, random forests, and support vectors were used to classify videos by the name of the exercise. The best machine learning results were obtained using the random forest classifier.

Keywords: Parkinson's disease, tremor, machine learning, intelligent system, development, software.

Статья поступила в редакцию 22.06.2024
Рекомендована к публикации профессором Федяевым О. И.

Анализ предметных областей и программных продуктов, использующих метод конечных элементов

Д. Н. Чернышов, А. В. Григорьев

Донецкий национальный технический университет
кафедра программной инженерии им. Л. П. Фельдмана
email: dima.ch2000@mail.ru, grigorievalv1@gmail.com

Аннотация:

В работе выполнен анализ применения математических вычислений с использованием метода конечных элементов. Рассмотрены и сравнены программы, включающие в себя указанный метод. Определены перспективы развития метода конечных элементов. Направление дальнейших исследований является использование результатов исследований для построения новых полезных модификаций метода конечных элементов, повышающих его эффективность и расширяющих области практического применения.

Введение

Одним из наиболее важных аспектов автоматизации проектирования является замена дорогостоящего и длительного экспериментального исследования опытного образца численным экспериментом, суть которого состоит в построении и исследовании с помощью компьютера математической модели проектируемого объекта. Кроме того, на практике не всегда имеется возможность испытаний опытных образцов, например, в авиастроении, так как это может привести к весьма серьёзным экономическим затратам, а иногда и к катастрофическим последствиям. При проектировании сложных инженерных и строительных конструкций наиболее важным элементом анализа является исследование их напряженно-деформированного состояния, что приводит к необходимости автоматизации решения с помощью ЭВМ задач механики деформируемого твёрдого тела. В силу сложности физической природы исследуемых явлений и их математического описания решения получают при весьма существенных ограничениях относительно свойств материалов, конструктивных форм, граничных и начальных условий. Поэтому для моделирования и анализа напряженно-деформированного состояния на практике часто используют различные численные методы. Наиболее развитым является метод конечных элементов.

Целью предлагаемой работы является анализ предметных областей и программных продуктов, использующих метод конечных элементов.

Сферы использования метода конечных элементов

Метод конечных элементов не один десяток лет известен в математике как способ численного решения задач, которые описываются дифференциальными уравнениями второго порядка

в частных производных. С помощью этого метода в настоящее время можно решить довольно большой спектр инженерных задач, проводя расчёты на персональном компьютере.

Этот численный метод решения дифференциальных уравнений, который широко применяется в различных предметных областях. Вот некоторые из них:

1) Механика и инженерия: В области механики МКЭ используется для анализа напряженно-деформированного состояния конструкций, расчета прочности материалов, оптимизации дизайна и т.д. Этот метод используется при проектировании автомобилей, самолетов, зданий, мостов, машин и других объектов.

2) Геофизика и геология: Метод конечных элементов применяется для моделирования геологических процессов, а также для анализа напряженно-деформированного состояния земной коры, распределения напряжений в горных породах и т.д. Это позволяет специалистам прогнозировать землетрясения, исследовать поведение грунтов и принимать меры по предотвращению опасных явлений.

3) Биомедицина: МКЭ применяется для моделирования биологических тканей, процессов течения крови, механики сердца, а также для создания и оптимизации медицинских устройств и имплантатов. Этот метод позволяет проводить виртуальные исследования, предсказывать результаты операций и разрабатывать новые методы лечения.

4) Электротехника и электроника: Метод конечных элементов используется для моделирования электромагнитных полей, анализа тепловых процессов, расчётов электрических цепей и других задач в области электричества и электроники. Этот метод помогает проектировать электрические машины, схемы управления, микроэлектронные устройства и другие изделия.

5) Математические исследования. МКЭ является одним из наиболее эффективных численных методов в исследовании краевых задач для дифференциальных уравнений с сингулярностью решения. Отличительной особенностью задач такого типа является то, что в большинстве случаев для них нельзя определить обобщённое (слабое) решение или оно не обладает достаточной регулярностью.

Кроме того, метод конечных элементов применяется в аэродинамике, химии, экологии, биофизике, строительстве, металлургии, гидродинамике и многих других областях науки и техники. Его универсальность и эффективность делают его одним из наиболее популярных численных методов в современной науке и инженерии.

Программное обеспечение с возможностями анализа МКЭ

На данный момент пользователям-инженерам предлагается большое разнообразие программных продуктов, использующих технологию МКЭ. Благодаря постоянному техническому прогрессу легче создавать более конкретные решения с отличными характеристиками. Программное обеспечение для анализа методом конечных элементов (МКЭ), сегодня является обычным инструментом для каждого инженера.

Многие из инженерных задач включают в себя проведение тестов, чтобы убедиться, что детали и материалы будут вести себя так, как ожидалось. Это включает реакции на различные ситуации, включая воздействие различных сил, вибрации и тепла. В прошлом такое тестирование проводилось путём создания прототипа продукта и проведения испытаний на нем. Однако создание прототипов и их испытание на них обычно требует времени и высоких затрат. Известно достаточно много конечно-элементных пакетов прикладных программ (ППП), в которых физические расчёты различных систем доведены до совершенства. Далее в работе проводится обзор самых мощных ППП со встроенными инструментами анализа методом конечных элементов. Выделение преимуществ и возможных ограничений каждого из них позволит выявить общую картину развития МКЭ на сегодняшний день.

COMSOL Multiphysics. Данный пакет (рис. 1) позволяет моделировать практически все физические процессы, которые описываются частными дифференциальными уравнениями. Программа содержит различные решатели, которые помогут справиться даже с самыми сложными задачами, а простая структура приложения обеспечивает простоту и гибкость использования. Пакет COMSOL Multiphysics, обладает почти такими же возможностями, как и пакет ANSYS, кроме этого, по сути, является инструментом пакета

MATLAB и работает под его управлением, т.е. все возможности программирования, доступные в MATLAB, могут быть использованы и в COMSOL Multiphysics, например при обработке результатов расчета. COMSOL Multiphysics обеспечивает возможность экспорта конечно-элементной модели в Simulink пакета MATLAB. Это позволяет моделировать работу объекта управления совместно с преобразователями электрической энергии, системами управления; исследовать частотные характеристики и устойчивость электротехнического комплекса. Но на практике трудности освоения интерфейса программы, накладываясь на ошибки создания моделей, делают процесс расчета недостаточно эффективным. Основные недостатки: высокая стоимость, отсутствие литературы на русском языке, труден в освоении [1].

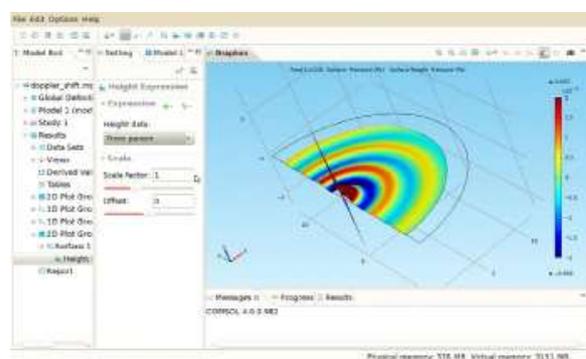


Рисунок 1 – Интерфейс COMSOL Multiphysics

ELCUT – это комплекс программ для инженерного моделирования электромагнитных, тепловых и механических задач методом конечных элементов. Основные плюсы данного программного комплекса: дружелюбный пользовательский интерфейс, простота описания моделей, широкие аналитические возможности комплекса и высокая степень автоматизации всех операций. ELCUT это полноценное Windows приложение, разработанное специально для этой платформы (рис. 2).

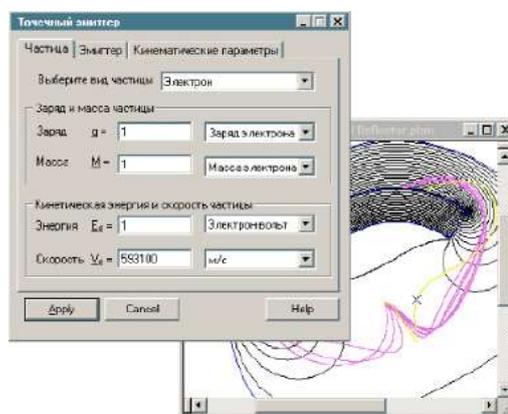


Рисунок 2 – Интерфейс ELCUT

Недостатки: двумерная геометрическая модель, а также отсутствует возможность

одновременного решения полевых задач (например, электромагнитной и тепловой) [2].

Maxwell – специализированный программный комплекс для моделирования электромагнитных полей.

Ключевые возможности: моделирование низкочастотных двумерных и трехмерных электромагнитных полей методом конечных элементов; переходный нелинейный анализ (при движении (вращение, поступательное движение, вращение по произвольной траектории) компонентов; стыковка с внешней электрической схемой; анализ размагничивания постоянного магнита; вычисление магнитных потерь); гармонический электромагнитный анализ; анализ вихревых токов с учётом скин-эффекта.

Комбинация Maxwell с программным комплексом Simplorer позволяет рассчитывать мощные высокоуровневые электромеханические системы. Подобные технологии позволяют выполнить комплексный расчет систем, состоящих из цифровых и аналоговых цепей, датчиков,

электромагнитных устройств, механических, гидравлических и других типов нагрузок, и в конечном счете создавать наиболее полную электромеханическую модель конечного продукта.

Также Maxwell позволяет передавать данные в модуль ePhysics для выполнения теплового и прочностного анализов. Основные недостатки: высокая стоимость [3].

Autodesk Inventor

Autodesk впервые завоевал мировую известность благодаря серии САПР для 2D-чертежей. Теперь Autodesk превратилась в одного из ведущих поставщиков программного обеспечения для САПР и анализа методом конечных элементов.

Inventor — это программное обеспечение Autodesk для механического проектирования и 3D-САПР (рис. 3). Он включает в себя классические функции САПР, такие как параметрическое моделирование, моделирование сборок и создание чертежей. Также этот программный пакет имеет более мощные новые инструменты, такие как автоматизация проектирования и моделирование.

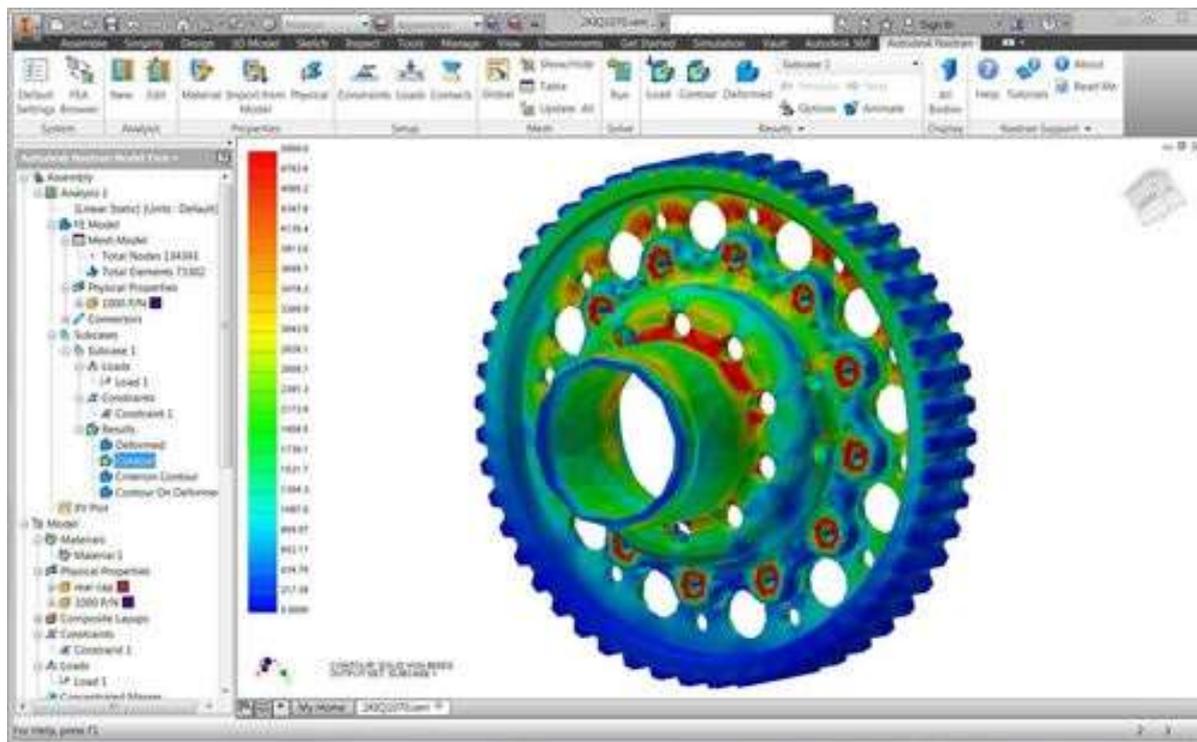


Рисунок 3 – Интерфейс Autodesk Inventor

Эта САПР также позволяет работать с конструкциями из листового металла в отдельной среде. Более того, система обеспечивает большую гибкость для визуализации, например разнесённые изображения и анимация воздействия.

Что касается возможностей анализа методом конечных элементов, в программе можно с лёгкостью запускать анализ статических или модальных напряжений и динамический анализ различных моделей. Пакет предоставляет диалоговое окно настроек, параметрическую

таблицу и руководство по моделированию, которые оказывают помощь пользователям в процессе моделирования.

Кроме того, от компании Autodesk также предлагается Inventor Nastran, который они определяют как встроенный в САПР модуль для анализа методом конечных элементов. Этот модуль является расширением возможностей анализа, предоставляемых Inventor. Он включает в себя более широкий спектр исследований и материалов для анализа. Одним из примеров таких исследований

можно назвать возможность запуска линейных и нелинейных исследований напряжения, динамики и теплопередачи [4].

Преимущества:

- Большая мощность программного обеспечения;
- В работе не требуется экспорт и импорт файлов;
- Доступен интерфейс на нескольких языках;
- Большая база знаний на веб-сайте компании и за её пределами, включая видеоуроки, статьи и форумы;
- Сборки и сварные детали также можно тестировать без необходимости сложных настроек.

Недостатки:

- В базовом виде возможности моделирования ограничены линейным напряжением и линейным динамическим анализом. Другие типы требуют использования модуля Inventor Nastran.

- Работает только в среде Windows.

Dassault Systemes SolidWorks

SolidWorks — это полный пакет САПР с различными модулями, включая одну из лучших программ CAD-CAM-CAE (рис. 4). Этот программный пакет является одним из основных конкурентов Autodesk Inventor. Создан компанией Dassault, базирующейся во Франции.

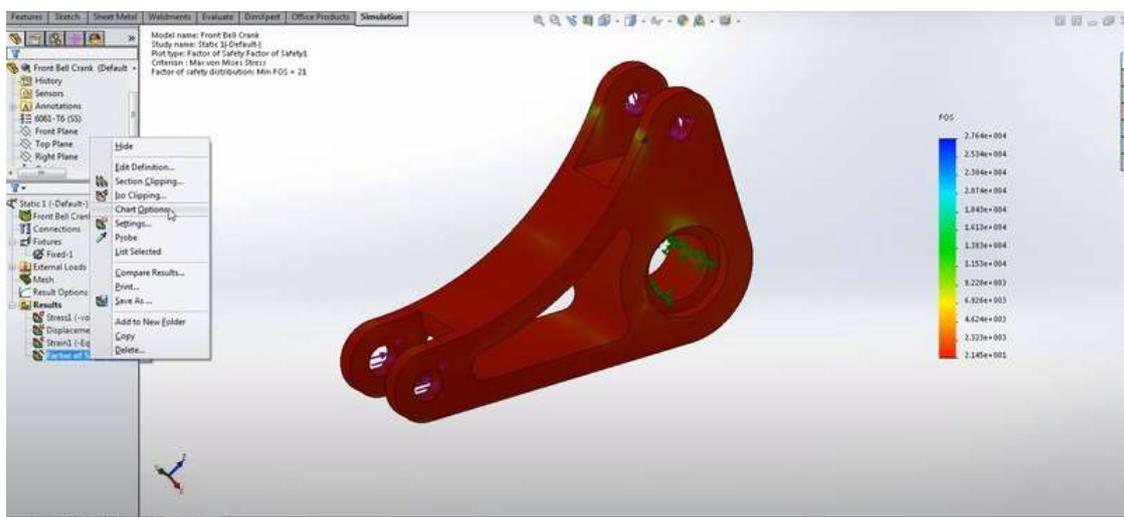


Рисунок 4 – Интерфейс SolidWorks

Среди основных функций SolidWorks выделяется возможность работы с большими и сложными сборками. Присутствует возможность работать с простой моделью и масштабировать её до полного комплекса объектов.

Анализ методом конечных элементов применяется через модуль SolidWorks Simulation. Модуль поставляется в трех уровнях: Standard, Professional и Premium. Последняя версия является наиболее мощной и включает в себя:

- Статические исследования;
- Исследования напряжений;
- Анализ движения;
- Термический анализ;
- Частотные исследования;
- Исследования потери устойчивости;
- Исследования сосудов под давлением;
- Оптимизация топологии;
- Линейные динамические исследования;
- Нелинейный анализ.

Кроме того, разработчики предлагают дополнения к SolidWorks Simulation. Они варьируются от моделирования потока и пластиковых упаковок до более конкретных решений. Например, модули Electronics Cooling и

Sustainability предоставляют пользователям возможности для проверки их проектов. Все эти пакеты и модули встроены в программное обеспечение.

Более того, для предоставления своим пользователям более широких возможностей МКЭ, Dassault Systemes SolidWorks предлагает ABAQUS через Simulia Structural Simulation Designer. Это специализированное программное обеспечение FEA, отлично совместимое с интерфейсом САПР [5].

Преимущества:

- Большая мощность программного обеспечения;
- Для проведения исследований не требуется экспорт и импорт файлов, поскольку создание изделия происходит в той же программе;
- Широкий спектр тестов в одном пакете;
- Могут быть выполнены гидродинамические тесты;
- Дополнения предлагаются как автономные решения, что даёт пользователю возможность платить только за то, что ему действительно нужно;

- Интерфейс доступен на нескольких языках;
- Большая база знаний на веб-сайте компании и за её пределами, включая видеоуроки, статьи и форумы.

Недостатки:

- В зависимости от версии и количества используемых модулей системные требования к аппаратному обеспечению могут быть достаточно высокими;

- Работает только в Windows.

Siemens Solid Edge — это полный набор инструментов для разработки, предлагаемых Siemens. Известная немецкая компания предлагает инструменты для механического и электрического проектирования, моделирования, производства, технических публикаций, управления данными и многого другого (рис. 5).



Рисунок 5 – Интерфейс Solid Edge

В последних версиях Solid Edge мы можем найти много новых функций. К ним относятся передовые технологии, такие как дополненная реальность и возможность полностью оцифровать процесс от проектирования до производства.

Еще одна выдающаяся функция Solid Edge — оптимизация как для аддитивного, так и для субтрактивного производства. Можно определить и выполнить ряд производственных процессов, в том числе:

- ЧПУ обработка;
- Резка;
- Изгиб;
- Литье;
- Сварка;
- Сборка;
- Производство добавок.

Последнее является хорошим дополнением благодаря достижениям в технологиях 3D-печати.

Solid Edge предлагает инструменты моделирования на трех разных уровнях: Solid Edge Premium, Solid Edge Simulation и Solid Edge Simulation Advanced. Масштабируемое моделирование Solid Edge позволяет пользователю в цифровом виде проверять и оптимизировать детали, сборки и целые системы. Вы можете сделать это на ранней стадии процесса проектирования, чтобы уменьшить потребность в быстром прототипировании и сэкономить время и деньги.

Возможности FEA в Solid Edge включают моделирование отдельных деталей, анализ сборки и

вычислительную гидродинамику (CFD). С помощью этого программного обеспечения САПР и анализа методом конечных элементов можно выполнять:

- Анализ напряжения и моделирование;
- Моделирование вибрации;
- Моделирование полного движения;
- Моделирование потери устойчивости;
- Тепловое моделирование.

Все варианты основаны на проверенной модели конечно-элементного моделирования Femap и технологии NX Nastran [6].

Плюсы:

- Мощное программное обеспечение от известной и проверенной компании;
- Встроенная САПР, экспорт и импорт файлов не требуются для проведения исследований;
- Широкий спектр возможностей в одном пакете;
- В программе могут быть выполнены аэро- и гидродинамические тесты;
- Поддержка клиентов доступна на нескольких языках;
- Большая база знаний на веб-сайте компании и за ее пределами, включая видеоуроки, вебинары, статьи, форумы и многое другое.

Минусы:

- В зависимости от используемой версии системные требования могут быть очень высокими по сравнению с другим программным обеспечением CAD и FEA;

• Последние версии ограничены Windows Enterprise или Professional.

PTC Creo. Creo — ещё одна известная компания в дизайнерском и инженерном сообществе. Их программное обеспечение для 3D проектирования и анализа методом конечных элементов является серьёзным конкурентом на рынке САПР. Creo предлагает масштабируемые пакеты и инструменты для разработки продуктов 3D CAD (рис. 6). Эти инструменты включают моделирование и проектирование, моделирование и анализ, дополненную реальность и аддитивное производство.



Рисунок 6 – Интерфейс Creo

В дополнение к возможностям 3D-проектирования, которые можно найти в любом программном обеспечении, Creo предлагает возможности для проектирования, основанного на знаниях. Пользователи могут использовать данные об использовании продукта в реальном мире с помощью функции Smart Connected Design. Возможности FEA в Creo расширились с годами. В последней версии была добавлена возможность проводить гидродинамические тесты с расширением Creo Flow Analysis. Еще одним компонентом является инструмент Creo Simulation Live, который обеспечивает мгновенную обратную связь в среде моделирования. Creo Simulation Live — самая замечательная функция, поскольку она

мгновенно предоставляет конструкторам структурный, тепловой и модальный анализы. Можно выполнять моделирование без необходимости создания сетки или упрощения моделей. Эта технология была создана в партнерстве с одним из самых уважаемых имен в индустрии инженерного программного обеспечения, ANSYS. Таким образом, Creo определенно повысила их авторитет и надежность на рынке.

Creo 6.0 позволяет выполнять: структурный анализ; термические испытания; анализ движения; моделирование усталости; анализ заполнения формы.

Все эти возможности делают его хорошим вариантом в качестве полноценного программного обеспечения для трёхмерной САПР и анализа методом конечных элементов [7].

Плюсы:

- Мощное программное обеспечение от известной и проверенной компании;
- Встроенная САПР, экспорт и импорт файлов не требуются для проведения исследований;
- Широкий спектр возможностей в одном пакете;
- Могут быть выполнены гидродинамические тесты и тесты заполнения формы;
- Поддержка клиентов доступна на нескольких языках;
- Большая база знаний на веб-сайте компании и за ее пределами, включая видеоуроки, вебинары, статьи, форумы и многое другое.

Минусы: моделирование ограничено уровнями Design Premium и Design Premium Plus; только для Windows.

Сравнение характеристик

Исходя из параметров программных продуктов, рассмотренных в этой работе, можно привести следующую таблицу сравнения характеристик программ (табл. 1).

Таблица 1 - Сравнение рассмотренных программ

Программа	COMSOL	ELCUT	Maxwell	Inventor	SolidWorks	Solid Edge	Creo
Документация	Да	Да	Да	Да	Да	Да	Да
Поддержка CAD	Нет	Да	Да	Да	Да	Да	Да
Решение тепловых и механических задач	Да	Да	Да	Да	Да	Да	Да
Вычисления электродинамики	Нет	Да	Да	Нет	Нет	Нет	Нет
Вычисления аэро- и гидродинамики	Да	Нет	Нет	Нет	Да	Да	Да
Размерность пространства, доступная для вычислений	0D-3D	2D	2D, 3D	2D, 3D	2D, 3D	2D, 3D	3D
Визуализация	Встроенная	Встроенная, сторонняя	Встроенная	Встроенная	Встроенная, сторонняя	Встроенная	Встроенная
Простота в освоении	Нет	Да	Да	Да	Да	Да	Да

Выводы

В предлагаемой работе выполнен анализ предметных областей и программных продуктов, использующих метод конечных элементов.

Как основной вывод, можно заметить, что инженерные вычисления с использованием метода конечных элементов довольно широко распространены в наше время. Рассмотренные программы же показывают динамику развития метода конечных элементов, что позволяет оценить его дальнейшие перспективы.

В качестве перспектив работы следует отметить, что результаты данного анализа можно использовать для построения новых полезных модификаций метода конечных элементов, повышающих его эффективность и расширяющих области практического применения.

Литература

1. Введение в COMSOL Multiphysics : Учебное пособие – США, 2018. URL: https://cdn.comsol.com/doc/5.4/IntroductionToCOMSOLMultiphysics.ru_RU.pdf. (дата обращения: 03.04.2024).
2. Инженерное моделирование квазистатического электромагнитного поля в программе ELCUT для задач электроники //

Электромагнитная совместимость в электронике : [сайт]. URL: <https://emc-e.ru/sapr/elcut/> (дата обращения: 12.04.2024).

3. ANSYS Maxwell | Моделирование электромагнитных полей // Моделирование и цифровые двойники : [сайт]. URL: <https://www.cadfecis.ru/products/ansys/electronics/maxwell/> (дата обращения: 17.04.2024).

4. Autodesk Inventor — уникальный инструмент для инженеров в новом тысячелетии // САПР и Графика : [сайт]. URL: <https://sapr.ru/article/7102> (дата обращения: 24.04.2024).

5. SolidWorks — стандарт трехмерного проектирования // САПР и Графика : [сайт]. URL: <https://sapr.ru/article/6733> (дата обращения: 30.04.2024).

6. Solid Edge: от CAD-системы до кабины пилота // CADMASTER – 2019 - №3(91). URL: https://www.cadmaster.ru/magazin/articles/cm_91_05.html (дата обращения: 03.05.2024).

7. PTC Creo Parametric. Лучшая CAD для проектирования // ИРИСОФТ : [сайт]. URL: <https://www.irisoft.ru/products/creo/ptc-creo-parametric/> (дата обращения: 11.05.2024).

Чернышов Д.Н., Григорьев А.В. Анализ предметных областей и программных продуктов, использующих метод конечных элементов. В работе выполнен анализ применения математических вычислений с использованием метода конечных элементов. Рассмотрены и сравнены программы, включающие в себя указанный метод. Определены перспективы развития метода конечных элементов. Направление дальнейших исследований является использование результатов исследований для построения новых полезных модификаций метода конечных элементов, повышающих его эффективность и расширяющих области практического применения.

Ключевые слова: метод конечных элементов, дифференциальные уравнения, САПР, CAE.

Chernishov D.N., Grigoriev A.V. Analysis of subject areas and software products that use the finite element method. The paper analyzes the application of mathematical calculations using the finite element method. The programs including the specified method are considered and compared. The prospects for the development of the finite element method are determined. The direction of further research is to use the research results to build new useful modifications of the finite element method, increasing its effectiveness and expanding the scope of practical application.

Keywords: finite element method, differential equations, CAD, CAE.

Статья поступила в редакцию 24.06.2024
Рекомендована к публикации профессором Федяевым О. И.

Особенности определения отношений в тезаурусе в области программирования

И. А. Коломойцева, С. С. Бердюкова

Донецкий национальный технический университет
кафедра Программной инженерии им. Л.П. Фельдмана
E-mail: bolatiger@mail.ru

Аннотация:

В статье выполнен анализ существующих модели информационного поиска. Рассмотрены особенности формирования тезауруса в области программирования. Обоснована необходимость использования такого тезауруса в информационном поиске. Описаны структура информационно-поисковой системы с использованием тезауруса и особенности отношений между понятиями в тезаурусе («ниже-выше», «часть-целое», ассоциации), позволяющие его отнести к формальным онтологиям.

Введение

Объём электронных документов, с которыми сталкивается человек, постоянно растёт. И задача поиска информации приобретает всё большую актуальность.

Под поиском информации понимается поиск в коллекции документов, которые являются наиболее релевантными по отношению к произвольным информационным потребностям, выражаемым (представленным) при помощи однократных запросов пользователей [1]. При этом информационная потребность – это тема, о которой пользователь хочет знать больше (следует её отличать от информационного запроса).

На сегодняшний день существуют модели информационного поиска, такие как, например, булев поиск, поиск с помощью векторно-пространственного представления, вероятностный поиск, языковые модели, в том числе, и большие языковые модели. Большие языковые модели (Large Language Models, LLM) успешно решают большинство задач информационного поиска, но обладают одним существенным недостатком. Для построения LLM нужен большой качественный датасет и большие вычислительные мощности [2]. При этом, в существующих моделях LLM редко учитываются особенности конкретных предметных областей. Решение, которое предлагается в этом случае, предусматривает доработку (расширение) существующей базовой модели LLM на датасете, состоящем из текстов, относящихся к выбранной предметной области. Но при таком подходе возникает зависимость от базовой модели LLM [3, 4].

Автором статьи предлагается другой подход к улучшению характеристик информационного поиска (полноты и в некоторых случаях точности) – использование

такого онтологического ресурса как информационно-поисковый тезаурус. Тезаурус – это словарь, в котором слова и словосочетания с близкими значениями сгруппированы в единицы, называемыми понятиями, концептами или дескрипторами, и в которых явно (в виде отношений, иерархии) указываются семантические отношения между этими понятиями [5]. С помощью тезауруса можно расширять за счёт свойств синонимии, ассоциации и зависимости терминов запроса. Способы расширения запроса описаны в [6].

Целью данной статьи является описание отношений в тезаурусе в области программирования.

Структура информационно-поисковой системы с использованием тезауруса

Информационный поиск – это процесс поиска в большой коллекции некоего неструктурированного материала (обычно – документа), удовлетворяющего информационные потребности [1].

Основными характеристиками информационного поиска являются точность и полнота [1].

Точность – доля релевантных документов среди найденных.

Полнота – доля найденных документов среди всех релевантных.

Показатель, позволяющий найти баланс между точностью и полнотой, называется F-мерой.

Найти нужную информацию пользователь может с помощью информационно-поисковой системы (ИПС). Информационно-поисковая система – это компьютерная система, предоставляющая пользователю возможность доступа к интересующей его информации из

некоторой коллекции документов, расположенной локально или в компьютерной сети, например, сети Интернет.

Общая структура информационно-поисковой системы включает в себя получение запроса от пользователя, предобработку этого запроса, отправку его в модуль поиска, получение списка документов, предположительно удовлетворяющих этому запросу, и ранжирование этого списка. Предобработка запроса нужна для того, чтобы термины запроса привести к тому же виду, что и термины документа. В этом случае запрос и документ из коллекции документов можно сравнивать между собой. Расширение запроса – это обычная практика, используемая в ИПС для повышения полноты поиска [7, 8]. Такие поисковые системы как Google или Yandex расширяли запрос с помощью статистического анализа предыдущих запросов самого пользователя и других пользователей. Сейчас крупные поисковые системы используют для уточнения запроса большие языковые модели.

Вместо сложных статистических моделей и LLM для улучшения характеристик поиска среди документов некоторой предметной области, например, программирования

предлагается использовать тезаурус, построенный по этой области. Тезаурус предлагается строить автоматически на основе относительно небольшого датасета. Структурная схема ИПС с использованием тезауруса представлена на рисунке 1.

Отношения в тезаурусе в области программирования

Отношения являются важной частью информационно-поискового тезауруса как онтологического ресурса.

Во-первых, именно отношения позволяют расширить запрос.

Во-вторых, отношения играют важную роль при разрешении многозначности. Для предметной области «Программирование», в которой многозначность терминов – частое явление, такая функция очень важна и при расширении запроса, и при анализе выдачи документов.

Для реализации любой из этих функций необходим своеобразный логический вывод: встретив понятие в запросе необходимо выполнять многошаговые проходы по отношениям.

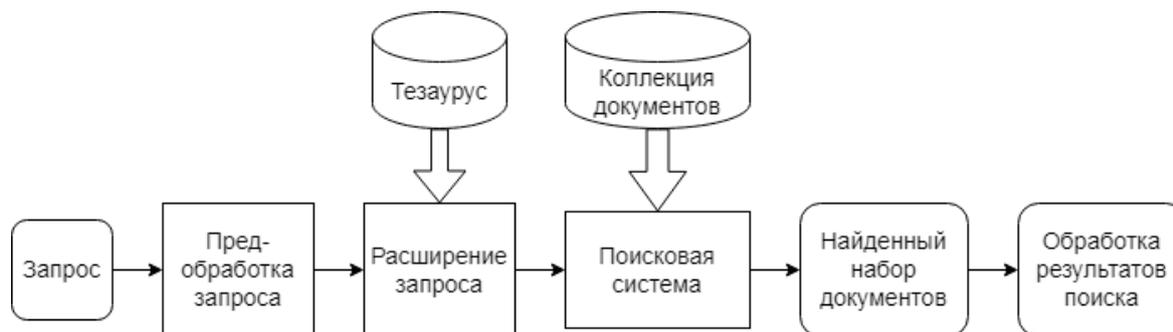


Рисунок 1 – Структура информационно-поисковой системы с использованием тезауруса

В информационно-поисковом тезаурусе по предметной области «Программирование», как и в большинстве информационно-поисковых тезаурусов [9, 10], используются отношения «выше-ниже», «часть-целое» и отношение ассоциации. При этом с отношением ассоциации могут возникать сложности из-за его субъективности.

И хотя в литературе неоднократно возникают предложения по замене информационно-поисковых тезаурусов, а более формализованные онтологии с более подробной системой отношений, но в [3] указано, что использование сложных онтологических формализмов нецелесообразно. Поэтому в информационно-поисковом тезаурусе для предметной области «Программирование» используется обычный набор отношений для такого рода ресурсов.

Принципы построения отношений

Отношение «выше-ниже» - это родовидовое отношение типа «класс-подкласс», обладает свойствами наследования и транзитивности. Относится к таксономическим отношениям.

Отношение «выше-ниже» обладают свойствами онтологических отношений «класс-подкласс», такими как [3]:

каждый пример видового понятия в любой момент своего существования должен быть примером родового понятия;

видовое понятие должно относиться к тому же семантическому классу, что и родовое понятие;

видовое понятие должно наследовать основные свойства родового понятия.

Таковыми же свойствами обладают отношения между ролевым понятием и понятием класса, если экземпляры только этого класса могут выступать в данной роли (МЕТОД КЛАССА – ФУНКЦИЯ).

Еще один тип отношений, обладающий такими свойствами, - это отношение между фазой какой-либо сущности и собственно этой сущностью (НАЧАЛЬНОЕ ЗНАЧЕНИЕ ПАРАМЕТРА – ПАРАМЕТР, ПОЛУЧЕННЫЙ В РЕЗУЛЬТАТЕ РАСЧЕТА).

Таким образом, отношение «выше-ниже» обладает свойствами несимметричности и транзитивности:

выше (X,Y) ^ выше (Y,Z) → выше (X,Z)
ниже (X,Y) ^ ниже (Y,Z) → ниже (X,Z)
выше (X,Y) → ниже (Y,X)

Но ещё больше сложностей возникает при построении тезауруса смещение типов и ролей в одной иерархии. Отношения тип-тип (анонимная функция - функция) и тип-роль (анонимная функция - замыкание) могут пройти все тесты установления родовидовых отношений. Но анонимная функция в любом случае останется функцией, и при этом она может быть замыканием, а может не быть им.

Отношение «часть-целое» играет очень важную роль в информационно-поисковых тезаурусах. Это связано с определением релевантности документа запросу пользователя. Можно предположить, что, если документ посвящен описанию части какого-то объекта, то он релевантен запросу, содержащему термин, определяющий целое. При этом сам термин, обозначающий термин, в документе может отсутствовать. Если, например, в документе описываются правила определения методов класса, то он с большой долей вероятности относится к понятию «класс в ООП» и «Объектно-ориентированному программированию». Примеры отношений «часть-целое» из тезауруса в области программирования приведены в таблице 1.

Таблица 1 - Примеры отношений «часть-целое» из тезауруса в области программирования

Часть	Целое
Метод	Класс
Оператор	Программа
Локальная переменная	Функция
Счётчик цикла	Цикл
Элемент массива	Массив
Объект ядра ОС	Ядро ОС
Стек потока	Поток
Контроллер	Паттерн MVC
Владелец мьютекса	Мьютекс

В лингвистике для определения отношения «часть-целое» используются лингвистические тесты – заданные предложения, в которые подставляются анализируемые сущности. Например, X – это часть Y, которое должно нормально звучать для некоторых X и Y. X (часть) называется меронимом, а Y (целое) – холонимом [4]. Это один из подходов, который используется при определении отношения «часть-целое» для тезауруса программирования. Задаются шаблонные фразы, по которой определяется, что X часть Y. Например, «X входит в Y», «X является частью Y» и т. п.

Второй подход является онтологическим. Важным принципом определения отношения «часть-целое» является следующее утверждение: уничтожение (изменение) предполагаемой части оказывает влияние на предполагаемое целое. Например, если из КОМПЬЮТЕРНОЙ ПРОГРАММЫ удалить все ОПЕРАТОРЫ, то КОМПЬЮТЕРНАЯ ПРОГРАММА прекратит своё существование. Наличие или отсутствие у МЬЮБЕКСА ВЛАДЕЛЬЦА МЬЮТЕКСа меняет состояние МЬЮТЕКСа (свободное/занятое).

Важным свойством отношения «часть-целое» является транзитивность. Благодаря этому свойству можно строить цепочки логического вывода. Например (читается слева направо):

МЕТОД – КЛАСС – ОБЪЕКТНО-ОРИЕНТИРОВАННОЕ ПРОГРАММИРОВАНИЕ
АТРИБУТ ЗАЩИТЫ – ОБЪЕКТ ЯДРА ОС – ЯДРО ОС

Отношение ассоциации – еще тип отношений, который присутствует в информационно-поисковом тезаурусе в области программирования. Отношение ассоциации, как и отношение «часть-целое», связано с релевантностью документа запросу. Считается, что если два понятия C1 и C2 связаны отношением ассоциации, то тексты, содержащие понятие C1, релевантны запросу, содержащему понятие C2, и наоборот. Например, такими понятиями являются ПОТОК и НИТЬ.

Вывод

Задача информационного поиска является сложной и актуальной задачей. Одним из подходов к решению этой задачи – является использование информационно-поискового тезауруса в конкретной области, в частности, в области программирования.

В работе рассмотрены особенности и сложности формирования тезауруса в области программирования. Определены отношения, встречающиеся в таком тезаурусе – «ниже-выше», «часть-целое» и ассоциации. Описано, какие сложности возникают при определении этих отношений.

Литература

1. Маннинг, К.Д. Введение в информационный поиск / К.Д. Маннинг, П. Рагхаван, Х. Шютце. – М.: ООО «И.Д. Вильмс», 2011. – 528 с.
2. Large Language Models for Information Retrieval: A Survey / Yutao Zhu, Huaying Yuan, Shuting Wang, Jiongnan Liu, Wenhan Liu, etc, - URL <https://paperswithcode.com/paper/large-language-models-for-information-retrieval> (дата обращения 01.03.2024).
3. Fine Tuning Large Language Model (LLM). – URL <https://www.geeksforgeeks.org/fine-tuning-large-language-model-llm/> (дата обращения 01.03.2024).
4. Филимонов, В. Ю. Большие языковые модели и их роль в современных научных открытиях / В. Ю. Филимонов // Философские проблемы информационных технологий и киберпространства. – 2024. – №1(25). – С. 42-57.
5. Лукашевич, Н.В. Тезаурусы в задачах информационного поиска / Н.В. Лукашевич. – М.: Издательство Московского университета, 2011. – 512 с.
6. Коломойцева, И.А. Применение тезауруса для расширения запроса информационно-поисковой системы на примере предметной области «Программирование» / И.А. Коломойцева // Материалы XIII Международной научно-технической конференции «Информатика, управляющие системы, математическое и компьютерное моделирование» (ИУСМКМ-2022). – Донецк: ДОННТУ, 2022. – С. 155-159.
7. Атаева, О. М. Формирование расширенных поисковых запросов на основе тезауруса предметной области в онтологии знаний семантической библиотеки / О. М. Атаева, В. А. Серебряков, Н. П. Тучкова // Электронные библиотеки. – 2020. – Т. 23, № 3. – С. 271-291.
8. Рогаленко, Н. А. Расширение поисковых запросов с использованием семантической сети с учетом контекста поиска / Н. А. Рогаленко // XII Конгресс молодых ученых : сборник научных трудов, Санкт-Петербург, 03–06 апреля 2023 года. – Санкт-Петербург: Национальный исследовательский университет ИТМО, 2023. – С. 373-377.
9. Гончаров, М. В. Применение тезаурусов при обработке поисковых запросов: от локального использования - к связанным данным / М. В. Гончаров, К. А. Колосов, Е. Ф. Бычкова // Научные и технические библиотеки. – 2022. – № 12. – С. 85-103.
10. Анализ тематических запросов удалённых пользователей Белорусской сельскохозяйственной библиотеки (с использованием дескрипторов тезауруса AGROVOC) / Р. А. Муравицкая, Н. С. Шакура, Е. В. Аксюто, В. В. Слемнева // Библиотечно-информационный дискурс. – 2023. – Т. 3, № 1. – С. 45-51.

Коломойцева И.А., Бердюкова С.С. Особенности определения отношений в тезаурусе в области программирования. В статье выполнен анализ существующих модели информационного поиска. Рассмотрены особенности формирования тезауруса в области программирования. Обоснована необходимость использования такого тезауруса в информационном поиске. Описаны структура информационно-поисковой системы с использованием тезауруса и особенности отношений между понятиями в тезаурусе («ниже-выше», «часть-целое», ассоциации), позволяющие его отнести к формальным онтологиям.

Ключевые слова: обработка естественного языка, информационный поиск, тезаурус, онтология, отношения, программирование.

Kolomoitseva I.A., Berdiukova S.S. Specifics of defining relationships in the thesaurus in the sphere of programming. The article analyzes the existing models of information retrieval. The features of the thesaurus formation in the field of programming are considered. The necessity of using such a thesaurus in information search is substantiated. The structure of an information retrieval system using a thesaurus and the features of the relationship between concepts in the thesaurus ("below-above", "part-whole", associations) are described, allowing it to be attributed to formal ontologies.

Keywords: natural language processing, information retrieval, thesaurus, ontology, relationships, programming.

Статья поступила в редакцию 24.06.2024
Рекомендована к публикации профессором Федяевым О. И.

Об авторах

Баев Дмитрий Эдуардович - аспирант кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Бердюкова Светлана Сергеевна - ассистент кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Боднар Алина Валериевна - кандидат технических наук, доцент, доцент кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Бондаренко Вадим Викторович - аспирант кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Волгушева Алёна Игоревна - магистрант кафедры компьютерной инженерии факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Григорьев Александр Владимирович - кандидат технических наук, доцент, доцент кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Зори Сергей Анатольевич - доктор технических наук, доцент, заведующий кафедрой программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Камбалина Алена Дмитриевна – магистрант отделения информационных технологий инженерной школы информационных технологий и робототехники ФГБОУ ВО «Томский политехнический университет».

Койбаш Александр Андреевич – старший преподаватель кафедры компьютерной инженерии факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Коломойцева Ирина Александровна – старший преподаватель кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Личман Антон Александрович – аспирант кафедры компьютерной инженерии факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Мальчева Раиса Викторовна - кандидат технических наук, доцент, доцент кафедры компьютерной инженерии факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Мулявин Дмитрий Евгеньевич - магистрант кафедры компьютерной инженерии факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Нестеренко Александра Романовна - студент кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Похлёбин Павел Сергеевич - магистрант кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Рудак Леонид Викторович - аспирант кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Рычка Ольга Валентиновна - кандидат технических наук, доцент, доцент кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Суханов Антон Алексеевич - студент кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Федяев Олег Иванович - кандидат технических наук, доцент, доцент кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Чередникова Ольга Юрьевна – кандидат технических наук, доцент, доцент кафедры компьютерной инженерии факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Чернышов Дмитрий Николаевич - аспирант кафедры программной инженерии им. Л. П. Фельдмана факультета интеллектуальных систем и программирования ФГБОУ ВО «Донецкий национальный технический университет».

Штепа Владимир Николаевич – доктор технических наук, заведующий кафедрой безопасности жизнедеятельности Белорусского государственного технического университета, г. Минск, Республика Беларусь.

**Требования к статьям,
направляемым в редакцию научного журнала
«Информатика и кибернетика»**

Редколлегией принимаются к рассмотрению статьи, в которых рассматриваются важные вопросы в области информатики и кибернетики. Научный журнал издаётся с 2015 года, периодичность издания – 4 раза в год.

В журнале предусмотрены следующие рубрики:

- информатика и вычислительная техника;
- компьютерные и информационные науки;
- инженерное образование.

В соответствии с номенклатурой специальностей научных работников МОН ДНР первые две рубрики соответствуют следующим укрупненным группам специальностей научных работников:

05.01 – «Инженерная геометрия и компьютерная графика»,

05.13 – «Информатика, вычислительная техника и управление».

С 01.02.2019 Научный журнал включён в Перечень рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание учёной степени кандидата наук, на соискание учёной степени доктора наук (приказ МОН ДНР № 135) по группам специальностей 05.01.00 и 05.13.00.

Рубрика «Инженерное образование» предназначена опубликования сотрудниками научно-методических статей.

Журнал также включён в базу данных РИНЦ (Российский индекс научного цитирования) (лицензионный договор № 425-07/2016 от 14.07.2016).

Статьи, представляемые в данный сборник, должны отвечать следующим требованиям. **Содержание статьи** должно быть посвящено актуальным научным проблемам и включать следующие необходимые элементы:

- постановку проблемы в общем виде, её связь с важными научными и практическими задачами;
- анализ последних исследований и публикаций, в которых решается данная задача и на которые опирается автор, выделение нерешенных ранее частей общей проблемы, которым посвящается статья;
- формулировка цели статьи и постановка задач, решаемых в ней;
- изложение основного материала с полным обоснованием полученных научных результатов;
- выводы и перспективы последующих исследований в данном направлении.

Каждый элемент должен быть выделен соответствующим названием раздела, например, «введение», «постановка задачи», «цель и задачи работы», «цель статьи», «цель исследования», «цель разработки», «анализ ... », «сравнительная оценка ... », «разработка ... », «проектирование ... », «программная реализация», «тестирование ... », «полученные результаты», «выводы», «литература». Разделы «введение», «выводы», «литература» являются обязательными. Включать в названия разделов нумерацию не разрешается.

В основном тексте статьи формулируются и обосновываются полученные авторами утверждения и результаты. Выводы должны полностью соответствовать содержанию основного текста. Языки публикаций: русский, английский.

Объём статьи, формат страницы

Для оформления статьи следует использовать листы формата А4 (210x297 мм) с полями по 2,5 см со всех сторон. Нумерацию страниц выполнять не нужно.

Рекомендуемый объём статьи – 6-12 страниц. Рукописи меньшего объёма могут быть рекомендованы к публикации в качестве коротких сообщений.

Последняя страница текста статьи должна быть заполнена не менее чем на две трети, но содержать не менее трёх пустых строк в конце.

Форматирование текста

Подготовка статьи осуществляется в текстовом редакторе Microsoft Office Word.

Весь текст статьи оформляется шрифтом Times New Roman 10 пт с одинарным междустрочным интервалом, если ниже в требованиях не сказано иного. Абзацный интервал «перед» – 0 пт, «после» – 0 пт.

На первой строке с выравниванием по левому краю располагается УДК.

Заголовок (название) статьи оформляется шрифтом Times New Roman 14 пт, полужирное начертание, с выравниванием по центру (без абзацных отступов). Заголовок статьи следует печатать с прописной буквы без точки в конце, переносы слов не допускаются. Абзацный интервал «перед» – 12 пт, «после» – 12 пт.

После названия статьи следует информация об авторах, которая выравнивается по центру (без абзацных отступов). На одной строке указываются инициалы и фамилии всех авторов через запятую. Между двумя инициалами ставится пробел. С новой строки указывается название вуза (организации) и город (для каждого автора, если не совпадают). На следующей строке указываются адреса электронной почты (один адрес либо каждого автора – по желанию). Адрес электронной почты оформляется в виде гиперссылки.

К тексту аннотации применяется курсивное начертание, с выравниванием по ширине, отступы слева и справа по 1 см. Заголовок «Аннотация» выделяется полужирным начертанием. Объём аннотации – 450-550 символов (без пробелов). Абзацный интервал «перед» – 12 пт, «после» – 12 пт.

Основной текст статьи разбивается на две колонки шириной по 7,5 см (промежуток между столбцами – 0,99 см), выравнивается по ширине. Абзацный отступ первой строки – 1 см. Автоматический перенос слов не применяется.

Заголовки разделов выполняются шрифтом Arial 10 пт, полужирное курсивное начертание. Абзацный отступ отсутствует, интервал перед абзацем – 12 пт, после абзаца – 6 пт. Для заголовка «Введение» установить интервал «перед» – 0 пт, «после» – 6 пт.

Таблицы в тексте статьи

Название следует помещать над таблицей с абзацного отступа (1 см) в формате: слово «Таблица», пробел, номер таблицы, пробел, тире, пробел, название таблицы. Название таблицы записывают с прописной буквы без точки в конце строки и выравнивают по ширине. В ячейках таблицы устанавливается выравнивание текста по центру по вертикали. По горизонтали текст выравнивается по центру либо по левому краю. Границы ячеек таблицы должны быть только чёрного цвета, толщина линии – 1 пт. На все таблицы должны быть приведены ссылки в тексте статьи, при ссылке следует писать слово «табл.» с указанием её номера, например, «... данные приведены в табл. 5». Таблицы нумеруются в пределах статьи. Таблица располагается сразу после ссылки на неё, если это возможно (например, после окончания абзаца). Если же таблица не помещается на текущей странице, то она должна быть расположена в начале следующей страницы (или колонки). При необходимости допускается включение в статью таблицы, ширина которой превышает ширину колонки. В этом случае таблица и её название размещаются по центру страницы. Таблица не должна выступать за границы полей страницы. Таблица и её название отделяются от основного текста статьи одной пустой строкой до и после.

Рисунки в статье

Ссылки на иллюстрации по тексту статьи обязательны и оформляются в виде «... на рис. 2» и т. п. Рисунок и его подпись выравниваются по центру колонки (без абзацных отступов), положение рисунка – «в тексте». Размещается рисунок после его первого упоминания в тексте, если это возможно (например, после окончания абзаца). Если же иллюстрация не помещается на текущей странице, то она должна быть расположена в начале следующей страницы (или колонки). При необходимости допускается включение в статью рисунка, ширина которого превышает ширину колонки. В этом случае рисунок и его подпись выравниваются по центру страницы. Иллюстрация не должна выступать за границы полей страницы. Подпись рисунка оформляется в формате: слово «Рисунок», пробел, номер иллюстрации, пробел, тире, пробел, название рисунка. Название рисунка записывают с прописной буквы без точки в конце строки. Для подписи иллюстрации применяют курсивное начертание. Иллюстрация и её подпись

отделяются от основного текста статьи одной пустой строкой до и после. Не допускается выполнять рисунки с помощью встроенного графического редактора Microsoft Office Word. Если на иллюстрации имеется текст, размер шрифта должен быть не менее чем аналогичный текст, набранный шрифтом Times New Roman 10-го размера. Иллюстрация не должна содержать много незаполненного пространства.

Формулы

Формулы и уравнения рекомендуется набирать с использованием MathType (предпочтительно) или MS Equation. Формулы и математические символы не должны существенно отличаться по размеру от основного текста. Обязательной является нумерация формул, на которые имеется ссылка в тексте статьи. Ссылки в тексте на порядковые номера формул дают в скобках, например, «... согласно формуле (2)». Формулы размещаются по центру колонки, а их номера – по правому краю. Как для строки с формулой, так и для первой строки пояснений (при наличии), абзацный отступ убирается. Первая строка пояснения начинается со слова «где», после которого следует поставить табуляцию на 1 см, затем само пояснение в формате: символ, подлежащий объяснению, пробел, тире, пробел, поясняющий текст, запятая, обозначение единицы измерения физической величины. Пояснения перечисляются через точку с запятой, выравниваются по ширине. Вторая и последующие строки пояснений начинаются с абзацного отступа (1 см). Весь блок текста, связанный с формулой (только формула, несколько формул подряд или формула с пояснениями), отделяется от основного текста одной пустой строкой до и после. Переносить формулы на следующую строку допускается только на знаках выполняемых операций, причем знак в начале следующей строки повторяют. При переносе формулы на знаке умножения применяют знак «×». Формулы и математические уравнения могут быть записаны в тексте документа, если их высота не превышает высоту строки. При этом следует учитывать, что знаки математических операций отделяются от чисел или символов пробелами с обеих сторон. Например, «Если учесть, что $y < 0$ и $2x + y = 1$, то из формулы (3) можно выразить $x...$ ». К символам, которые приведены в формуле, при дальнейшем их употреблении (в том числе в пояснениях к формуле) должно применяться курсивное начертание. При этом к любым числам (верхние и нижние индексы, содержащие цифры и т.п.), а также к математическим знакам курсивное начертание не применяется. Не допускается вставлять формулы, выполненные в виде рисунков.

Перечисления: оформление списков

Основной текст статьи может содержать перечисления, оформленные в виде маркированного списка. В качестве маркера элемента списка разрешается использовать только короткое тире «–». Каждый элемент перечисления записывается с новой строки с абзацного отступа, равного 1 см. После символа короткого тире текст располагается с отступом в 1,5 см от левой границы строки, выравнивается по ширине, при переносе на новые строки располагается без отступов. Нумерованные и многоуровневые списки включать в статью не разрешается.

Литература

В тексте статьи обязательны ссылки на все литературные источники, номер источника указывается в квадратных скобках. Ссылки на неопубликованные работы не допускаются. Рекомендуемое количество источников, на которые ссылается автор, не менее 10. Перечень источников приводится в порядке их упоминания в статье. Библиографическое описание каждого литературного источника оформляется в соответствии с ГОСТ Р 7.0.100–2018. Перечень литературных источников оформляется в виде нумерованного списка. В качестве маркеров элементов списка используют порядковые арабские цифры с точкой. Каждый источник представляет собой отдельный элемент перечисления, записывается с новой строки с абзацного отступа, равного 1 см. После порядкового номера с точкой текст располагается с отступом в 1,5 см от левой границы строки, выравнивается по ширине, при переносе на новые строки располагается без отступов.

В конце статьи обязательно приводятся аннотации на русском и английском языках, каждая заканчивается перечнем 5-6 ключевых слов.

К тексту аннотации применяется курсивное начертание, с выравниванием по ширине, отступы слева и справа по 1 см. Слово «Аннотация» опускается. Текст аннотации начинается с ФИО авторов и названия статьи, выделяемых полужирным начертанием. Аннотация на русском языке совпадает с аннотацией, приведенной в начале статьи. В тексте аннотации на английском языке после фамилии автора указывается только первая буква имени с точкой. Абзацный интервал «перед» – 12 пт, «после» – 12 пт. Ключевые слова оформляются с новой строки аналогично тексту аннотации. Заголовок «Ключевые слова:» (англ. «Keywords:») выделяется полужирным начертанием. Ключевые слова перечисляются через запятую.

Порядок представления статьи и сопроводительные документы

В редакцию необходимо представить:

- файл с текстом статьи;
- файл, содержащий фамилию, имя и отчество авторов полностью; ученую степень, ученое звание; место работы с полным указанием должности, подразделения и наименования организации, города (страны); номера телефонов и e-mail для связи;
- экспертное заключение о возможности публикации статьи, подписанное руководителем и заверенное печатью организации, в которой работает автор статьи;
- выписка из заседания кафедры или письмо организации с просьбой об опубликовании и указанием, что изложенные в статье результаты ранее не публиковались.

Статьи и сопроводительные документы следует высылать на электронный адрес infcyb.donntu@yandex.ru.

К сведению авторов

Если статья оформлена с нарушением указанных выше требований и правил, редакция после предварительного рассмотрения может отклонить статью.

На рецензирование статьи направляются членам редакционной коллегии журнала. Все статьи публикуются при наличии положительной рецензии.

В статью могут быть внесены изменения редакционного характера без согласования с автором. Ответственность за содержание статьи и качество перевода аннотаций несут авторы.

Публикация статей в научном журнале «Информатика и кибернетика» осуществляется на некоммерческой основе.

Все номера Научного журнала размещаются в электронной библиотечной системе ФГБОУ ВО «ДонНТУ» и на сайте <http://infcyb.donntu.ru/>.

CONTENT

Informatics and computer engineering

Research on machine and deep learning algorithms for detecting tumors in the human brain <i>Bondarenko V. V., Rychka O. V.</i>	5
Expanding the capabilities of image generation systems by using neural networks <i>Mulyavin D. E., Malcheva R. V., Koibash A. A.</i>	13
Intellectualization algorithms and their application in automated control systems <i>Lichman A. A. Cherednikova O. Yu.</i>	19
Investments in artificial intelligence: assessment of economic feasibility and potential risks <i>Pokhlebin P. S., Bodnar A.V., Nesterenko A.R.</i>	25
Application of convolutional neural networks for object recognition in an image <i>Volgusheva A. I., Malcheva R. V.</i>	32
Text processing using natural language methods <i>Rudak L. V., Zori S. A.</i>	39
Video recording of students' presence in the classroom based on neural network facial recognition <i>Sukhanov A. A., Baev D. E., Fedyaev O. I.</i>	45
Rational approaches to the implementation digital twins in water supply and sewerage systems <i>Shtepa V. N.</i>	51
The intelligent system for assessing postural and kinetic tremor in patients diagnosed Parkinson's disease <i>Kambalina A. D.</i>	58
Analysis of subject areas and software products that use the finite element method <i>Chernishov D. N., Grigoriev A. V.</i>	63
Specifics of defining relationships in the thesaurus in the sphere of programming <i>Kolomoitseva I. A., Berdiukova S. S.</i>	70
<u>About Authors</u>	74
<u>Requirements to articles which are sent to the editors office of the scientific journal "Informatics and Cybernetics"</u>	76

Электронное периодическое издание

Научный журнал

ИНФОРМАТИКА И КИБЕРНЕТИКА

(на русском, английском языках)

№ 3 (37) - 2024

Ответственный за выпуск Р. В. Мальчева

Технический редактор Р. В. Мальчева

Компьютерная верстка Р. В. Мальчева

Подписано к выпуску 20.06.2024. Усл. печ. лист. 9,2. Уч.-изд. лист. 6,1.
Адрес редакции: ДНР, 283001, г. Донецк, ул. Артема, 58, ФГБОУ ВО «ДонНТУ»,
4-й учебный корпус, к. 36.

Тел.: +7 (856) 301-07-35, +7 (949) 334-89-11

E-mail: infcyb.donntu@yandex.ru, URL: <http://infcyb.donntu.ru>