

**МИНИСТЕРСТВО СЕЛЬСКОГО ХОЗЯЙСТВА РОССИЙСКОЙ
ФЕДЕРАЦИИ**
**РОССИЙСКИЙ ГОСУДАРСТВЕННЫЙ АГРАРНЫЙ УНИВЕРСИТЕТ –
МСХА имени К.А. ТИМИРЯЗЕВА**



**Материалы
заседания секции «Нейронные сети на языке Python в АПК»
Международной научно-практической конференции «Цифровые
компетенции – сельскому хозяйству»**

16 октября 2025г

Москва
Издательство РГАУ-МСХА
2025

УДК 378.147:63:004.8

ББК 74.202.53:40

М 34

Редакционная коллегия:

директор института экономики и управления АПК,

д.э.н., профессор, **Л. И. Хоружий**,

и.о. заведующего кафедрой статистики и кибернетики, к.э.н., доцент **А.В. Уколо́ва**,

заместитель директора института по науке и практике,

ассистент кафедры статистики и кибернетики, **К.А. Козлов**,

доцент кафедры статистики и кибернетики, к.э.н., доцент **В.В. Демичев**,

доцент кафедры статистики и кибернетики, к.э.н. **Б.Ш. Дашиева**,

доцент кафедры статистики и кибернетики, к.э.н. **М.К. Джикия**,

ассистент кафедры статистики и кибернетики, ассистент **А.Д. Титов**,

старший преподаватель кафедры статистики и кибернетики, **Д. В. Быков**,

ассистент кафедры статистики и кибернетики, **Д.А. Титова**,

Материалы заседания секции «Нейронные сети на языке Python в АПК» Международной научно-практической конференции «Цифровые компетенции – сельскому хозяйству»: сборник статей / Коллектив авторов; Под ред. Л.И. Хоружий, А.В. Уколо́вой, К.А. Козловым, В.В. Демичева, Б.Ш. Дашиевой, М.К. Джикии, А.Д. Титова, Д.В. Быкова, Д.А. Титовой, [Электронный ресурс]

ISBN 978-5-9675-2098-3

В сборник включены статьи по материалам докладов студентов, молодых ученых, преподавателей и аспирантов заседания секции «Нейронные сети на языке Python в АПК» Международной научно-практической конференции «Цифровые компетенции – сельскому хозяйству».

Сборник предназначен для студентов бакалавриата, магистратуры, аспирантов, преподавателей, научных работников, специалистов сельскохозяйственного производства.

© Коллектив авторов, 2025

© ФГБОУ ВО РГАУ – МСХА имени
К.А. Тимирязева, 2025

Содержание

Акименко Д.Д., Храмов Д.Э.

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДЛЯ ОЦЕНКИ СТРУКТУРЫ И КОНТЕНТА РЕЗЮМЕ В TELEGRAM: КОНЦЕПЦИЯ И АРХИТЕКТУРА ПРОЕКТА 5

Андросова И.И., Журавлева Ю.С., Титов А.Д.

ПРОГНОЗ УРОЖАЙНОСТИ КУКУРУЗЫ ПО ПОГОДНЫМ ДАННЫМ С ПОМОЩЬЮ НЕЙРОННОЙ СЕТИ НА РУНТОН 12

Анохин И.А.

АНАЛИЗ ЗАРУБЕЖНЫХ ИНФОРМАЦИОННЫХ РЕСУРСОВ В КОНТЕКСТЕ ВНЕШНЕЭКОНОМИЧЕСКОЙ ДЕЯТЕЛЬНОСТИ АПК 16

Бородкина Е.И., Хоружий Л.И.

ПЕРСПЕКТИВА ИСПОЛЬЗОВАНИЯ НЕЙРОННЫХ СЕТЕЙ В АПК 24

Британова А.А., Шапошникова Е.Е.

ВЛИЯНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ВЕБ-РАЗРАБОТКУ 27

Бычкова М.А., Анохин И.А.

ОБНАРУЖЕНИЕ АНОМАЛИЙ НА ОСНОВЕ ПОЛНОСВЯЗНОЙ НЕЙРОННОЙ СЕТИ АВТОЭНКОДЕРНОГО ТИПА 31

Галимуллин Д.Р., Нечаев А.С., Токарев В.С.

ИНТЕЛЛЕКТУАЛЬНЫЙ АССИСТЕНТ ДЛЯ СТУДЕНТА НА PYTHON: ИННОВАЦИОННОЕ РЕШЕНИЕ ДЛЯ СОВРЕМЕННОГО ОБРАЗОВАНИЯ 34

Голубев А.С., Савельев А.Р., Демичев В.В.

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В МЕДИЦИНСКОЙ ДИАГНОСТИКЕ 38

Гребёнкин А.М., Никаноров М.С., Степанцевич М.Н.

ERP-СИСТЕМЫ В УПРАВЛЕНИИ СЕЛЬСКИМ ХОЗЯЙСТВОМ 43

Гребёнкин А.М., Никаноров М.С., Степанцевич М.Н.

АНАЛИЗ НАПРАВЛЕНИЙ ЦИФРОВИЗАЦИИ АГРОПРОМЫШЛЕННОГО КОМПЛЕКСА 48

Гридин М.М., Арзуманян А.А., Уколова А.В.

АВТОМАТИЗИРОВАННАЯ ИДЕНТИФИКАЦИЯ БОЛЕЗНЕЙ И ВРЕДИТЕЛЕЙ СЕЛЬСКОХОЗЯЙСТВЕННЫХ КУЛЬТУР ПО ФОТОГРАФИЯМ С ПОМОЩЬЮ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ НА PYTHON 52

Гринь В.А., Храмов Д.Э.

ЭФФЕКТИВНОСТЬ ТРАНСФЕРНОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ НА ДАТАСЕТЕ CIFAR-10: СРАВНЕНИЕ ПОДХОДОВ И ВЛИЯНИЕ АРХИТЕКТУРЫ МОДЕЛИ 58

Громов Г.Д., Бодур А.М.

БОЛЬШИЕ ЯЗЫКОВЫЕ МОДЕЛИ (LLM) ДЛЯ ИНТЕЛЛЕКТУАЛИЗАЦИИ ПРОИЗВОДСТВЕННЫХ ПРОЦЕССОВ В АПК 62

Зюбин К.А., Храмов Д.Э.

ОБНАРУЖЕНИЕ ФЕЙКОВЫХ НОВОСТЕЙ 66

Казлаускас А.С., Мерзлякова М.А., Храмов Д.Э.	
АВТОМАТИЧЕСКАЯ ДИАГНОСТИКА ЗАБОЛЕВАНИЙ РАСТЕНИЙ: ЭВОЛЮЦИЯ ОТ КЛАССИФИКАЦИИ К ДЕТЕКЦИИ.....	74
Клужин А.С., Рязанкин К.А., Дашиева Б.Ш.	
ОСОБЕННОСТИ РЕШЕНИЯ ПРОБЛЕМЫ ПЕРЕОБУЧЕНИЯ МОДЕЛИ НЕЙРОННОЙ СЕТИ МЕТОДОМ DROPOUT	77
Кокорева В.А., Демичев В.В.	
ОПТИМИЗАЦИЯ БИЗНЕС-ПРОЦЕССОВ В МИКРОБИЗНЕСЕ	82
Кошенков Д.В., Руссу А.М., Титов А.Д.	
КОМПЬЮТЕРНОЕ ЗРЕНИЕ В СЕЛЬСКОМ ХОЗЯЙСТВЕ.....	85
Кудрявцев В.А., Титов А.Д.	
ИНТЕЛЛЕКТУЛЬЯНЫЕ СИСТЕМЫ НА PYTHON КАК ИНСТРУМЕНТ ЦИФРОВИЗАЦИИ АПК	91
Лапин Н.Г., Шеболдин А.Д., Храмов Д.Э.	
ПРИМЕНЕНИЕ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ВЫЯВЛЕНИЯ ВРЕДОНОСНОГО ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ В ІОТ-УСТРОЙСТВАХ АГРОПРОМЫШЛЕННОГО КОМПЛЕКСА.....	94
Маврин А.М., Титов А.Д.	
РАЗРАБОТКА СИСТЕМЫ АВТОМАТИЧЕСКОЙ ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ РАСТЕНИЙ МЕТОДАМИ ГЛУБОКОГО ОБУЧЕНИЯ НА PYTHON.....	99
Маханьков Т.М., Невзоров А.С.	
ПОГОНЯ ЗА РАЗУМОМ: ЛУЧШИЕ ПОПЫТКИ СОЗДАНИЯ AGI.....	101
Наследов А.В., Дашиева Б.Ш.	
АНАЛИЗ ЗАРУБЕЖНОГО ОПЫТА СОЗДАНИЯ ИНФОРМАЦИОННОЙ СИСТЕМЫ МОНИТОРИНГА РАЗВИТИЯ БИОЭКОНОМИКИ	105
Рыбалкин Б.А., Анохин И.А.	
PANDAS И SCIKIT-LEARN: КАК ПОДГОТОВИТЬ ДАННЫЕ ДЛЯ УСПЕШНОГО ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ.....	109
Солженицына М.С., Маслакова В.В.	
ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ ПРОТИВ БОЛЕЗНЕЙ РАСТЕНИЙ: СИЛА НЕЙРОННЫХ СЕТЕЙ RESNET И EFFICIENTNET.....	114
Шадыкулов А.Р., Титов А.Д.	
ПРИМЕНЕНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСПОЗНАВАНИЯ ИЗОБРАЖЕНИЙ С ИСПОЛЬЗОВАНИЕМ PYTHON И TENSORFLOW.....	117

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДЛЯ ОЦЕНКИ СТРУКТУРЫ И КОНТЕНТА РЕЗЮМЕ В TELEGRAM: КОНЦЕПЦИЯ И АРХИТЕКТУРА ПРОЕКТА

Акименко Даниил Денисович, студент 2 курса института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, akimenko192837465@gmail.com

Научный руководитель – Храмов Дмитрий Эдуардович, старший преподаватель кафедры статистики и кибернетики, ФГБОУ ВО РГАУ-МСХА имени К. А. Тимирязева, kramovde@rgau-msha.ru

Аннотация. Цель доклада заключается в представлении концепции и архитектуры проекта по разработке нейросетевой модели для автоматизированной оценки структуры и содержания резюме. Актуальность решения обусловлена комплексом проблем как для соискателей, связанных с отсутствием качественной обратной связи и недостатком экспертной поддержки, так и для HR-специалистов, страдающих от рутинного скрининга и субъективности оценок. В работе детально описывается архитектура системы на основе гибридной нейросетевой модели, интегрированной в Telegram-бота, а также ключевые критерии оценки резюме, включая структурные, содержательные и языковые параметры. Особое внимание уделяется методологии проектирования системы и ожидаемым практическим результатам, которые позволяют повысить эффективность процессов трудоустройства и рекрутинга.

Ключевые слова: нейросетевая модель; оценка резюме; искусственный интеллект; Telegram-бот; HR-технологии.

NEURAL NETWORK MODEL FOR EVALUATING RESUME STRUCTURE AND CONTENT IN TELEGRAM: PROJECT CONCEPT AND ARCHITECTURE

Akimenko Daniil Denisovich, 2nd-year student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU-MSHA), akimenko192837465@gmail.com

Scientific Supervisor – Kramov Dmitry Eduardovich, Senior Lecturer, Department of Statistics and Cybernetics, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU-MSHA), kramovde@rgau-msha.ru

Abstract. The purpose of this report is to present the concept and architecture of a project aimed at developing a neural network model for the automated evaluation of resume structure and content. The relevance of this solution stems from a range of challenges faced both by job seekers—such as the lack of high-quality feedback and insufficient expert guidance—and by HR professionals, who struggle with repetitive screening tasks and subjective assessments. The paper provides a detailed description of the system architecture based on a hybrid neural network model integrated into a Telegram bot, as well as the key resume evaluation criteria, including structural, content-related, and linguistic parameters. Special emphasis is placed on the system design methodology and anticipated practical outcomes, which are expected to enhance the efficiency of job placement and recruitment processes.

Keywords: neural network model; resume evaluation; artificial intelligence; Telegram bot; HR technologies.

Введение

В условиях активной цифровой трансформации современных бизнес-процессов разработка систем автоматизированной оценки резюме представляет собой особо перспективное и востребованное направление в сфере управления персоналом. Интенсивное развитие технологий искусственного интеллекта открывает новые возможности для оптимизации рутинных операций, что особенно актуально в контексте рекрутинговой деятельности. Современные вызовы, стоящие перед рынком труда, требуют инновационных подходов к решению накопившихся проблем, связанных с обработкой больших объемов информации и необходимостью обеспечения объективности оценки кандидатов. Предлагаемый проект будет направлен на создание нейросетевой модели, интегрированной в Telegram-бот для повышения доступности технологии, что особенно актуально для русскоязычного сегмента рынка труда. Актуальность такого решения определяется необходимостью преодоления системных проблем, существующих на современном рынке труда и требующих комплексного подхода к их решению.

Проблематика и актуальность разработки системы

Для HR-специалистов характерно выгорание от рутины, вызванное ежедневным монотонным скринингом десятков однотипных резюме, при этом субъективность оценки, усугубляемая усталостью и когнитивными искажениями, значительно повышает риск пропустить перспективного кандидата. Низкая эффективность процесса проявляется в том, что до 80% рабочего времени тратится на первичный, а не на содержательный отбор, что свидетельствует о необходимости оптимизации данного процесса. Психологические аспекты профессиональной деятельности рекрутеров часто остаются без должного внимания, хотя именно они во многом определяют качество отбора персонала. Со стороны соискателей проблематика заключается в информационном вакууме, когда массовые отказы без развернутой обратной связи не позволяют понять и исправить ошибки, что создает порочный круг профессионального развития.

Отсутствие доступной экспертизы приводит к цикличности ошибок, когда одни и те же слабые формулировки и структурные недочеты кочуют из резюме в резюме, снижая общее качество представляемых на рынок кандидатур. Дополнительным аспектом является существенный рыночный пробел, поскольку существующие аналоги представляют собой преимущественно зарубежные веб-платформы, не учитывающие специфику российского рынка труда и организацию HR-процессов, а ниша мгновенной оценки резюме прямо в мессенджере остается практически свободной, что создает благоприятные условия для внедрения инновационного решения. Необходимо отметить, что современные тенденции развития коммуникационных технологий свидетельствуют о растущей популярности мессенджеров как платформы для предоставления различных услуг, что делает выбор Telegram особенно перспективным с точки зрения охвата целевой аудитории. «ИИ» традиционно относится к широкому классу технологий, которые позволяют компьютеру для выполнения задач, которые обычно требуют человеческого познания, включая принятие решений ... которые полагаются главным образом, на основе возросшей доступности данных для задач прогнозирования [1, с.1].

Цель, задачи и архитектура проекта

Цель проекта охватывает разработку и внедрение в Telegram-бота нейросетевой модели для автоматизированной оценки качества структуры и контента резюме с последующей возможностью масштабирования решения. Для достижения этой цели предстоит решить комплекс взаимосвязанных задач, среди которых анализ существующих решений на рынке с определением их сильных и слабых сторон, формирование системы критериев качества резюме на основе экспертных оценок, проектирование архитектуры нейросетевой модели для оценки и генерации персонализированных советов, определение оптимального технологического стека и поэтапного плана разработки, а также формулирование требований к данным и методов их разметки для обеспечения качества обучения модели. Каждая из этих задач требует тщательной проработки и учета множества факторов, включая технические возможности, потребности пользователей и особенности предметной области.

Такой комплексный подход позволит создать специализированный инструмент, соответствующий современным тенденциям развития искусственного интеллекта и отвечающий конкретным потребностям российского рынка труда. Особое внимание будет уделено обеспечению практической ценности решения как для соискателей, так и для рекрутеров, что повысит востребованность разрабатываемого продукта. Важным аспектом является также образовательная составляющая проекта, которая продемонстрирует полный жизненный цикл создания ML-продукта – от первоначальной концепции до рабочего прототипа. Необходимо подчеркнуть, что успешная реализация проекта потребует междисциплинарного подхода, сочетающего знания в области компьютерных наук, лингвистики и управления персоналом.

Нейронные сети не программируются в привычном смысле этого слова, они обучаются. Возможность обучения – одно из главных преимуществ нейронных сетей перед традиционными алгоритмами. Технически обучение заключается в нахождении коэффициентов связей между нейронами. В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными и выходными данными, а также выполнять обобщение. Это значит, что в случае успешного обучения сеть сможет вернуть верный результат на основании данных, которые отсутствовали в обучающей выборке, а также неполных и/или «зашумлённых», частично искажённых данных [2].

Одним из ключевых инструментов для реализации нейро-сетевых архитектур и алгоритмов глубокого обучения является язык программирования Python. Благодаря наличию мощных библиотек, таких как TensorFlow и Keras, создание и обучение нейронных сетей на Python стало достаточно простым [3].

Архитектура системы будет построена как последовательность логически взаимосвязанных компонентов, где пользователь взаимодействует с системой через интуитивно понятный Telegram-бот, выполняющий роль основного интерфейса. Бот будет принимать резюме в различных форматах – как в виде файла, так и текстового сообщения, и передавать данные на Backend API, который выступит в качестве мозгового центра системы, осуществляя извлечение текста, его предварительную обработку и нормализацию для последующего анализа. Важной особенностью архитектуры является ее модульность, позволяющая независимо развивать и совершенствовать отдельные компоненты системы без необходимости перестройки всей структуры. Данные процессы подробно описаны в [4].

Затем структурированная информация поступит в NLP-модель, являющуюся ядром всей системы, где будет проводиться комплексный анализ структуры и содержания резюме с формированием детализированных рекомендаций по улучшению. После завершения многоуровневого анализа сгенерированный ответ будет передаваться обратно через Backend в Telegram-бота для представления пользователю в удобочитаемом и структурированном виде, обеспечивая тем самым замкнутый цикл взаимодействия. Каждый компонент системы будет разрабатываться с учетом принципов модульности и масштабируемости, что позволит в будущем легко расширять функциональность системы. Особое значение имеет обеспечение надежности и отказоустойчивости системы, поскольку она будет работать с персональными данными пользователей. Небольшое отступление. Телеграмм умеет сообщать боту о действиях пользователя двумя способами: через ответ на запрос сервера (Long Poll), и через Webhook, когда сервер Телеграмма сам присыпает сообщение о том, что кто-то написал боту. Второй способ явно выглядит лучше, но требует выделенного IP-адреса, и установленного SSL на сервере. В этой статье я хочу рассказать о написании бота, а не настройке сервера, поэтому пользоваться мы будем Long Poll'ом [5].

Ключевые критерии оценки резюме

Система критериев оценки будет построена на основе многомерного анализа по трем ключевым направлениям, обеспечивающим комплексный

подход к оценке качества резюме. Структура резюме будет оцениваться по полноте содержания ключевых разделов, охватывающих контактную информацию, опыт работы, образование, навыки и достижения, а также по логической последовательности их расположения, оптимальному объему каждого блока и эффективности выделения ключевой информации. Не менее важным аспектом является визуальное оформление документа, хотя в рамках текущего проекта основной акцент делается на содержательные характеристики.

Содержательная часть будет анализировать конкретику формулировок с акцентом на наличие глаголов действия, демонстрацию измеримых результатов в виде количественных показателей и метрик эффективности, релевантность содержания заявленной целевой должности и уникальность достижений без использования шаблонных фраз. Языковые критерии будут включать грамотность написания с точки зрения орфографии и пунктуации, соответствие профессиональной стилистике с использованием соответствующей лексики и терминологии, читаемость текста через анализ длины предложений и наличия логических связок, а также адекватность тона изложения, который должен быть профессиональным, но не излишне формальным.

Итоговый вывод модели будет содержать общий интегральный балл качества по шкале от 1 до 10, детализированныйフィードбек по каждому анализируемому критерию с указанием сильных и слабых сторон, сгенерированные персонализированные рекомендации и конкретные примеры переформулировок проблемных участков текста. Такой всесторонний подход к оценке позволит пользователям не только получить общее представление о качестве своего резюме, но и понять конкретные направления для его улучшения. Важно отметить, что система будет разрабатываться с учетом принципов объяснимого искусственного интеллекта, чтобы пользователи могли понимать логику принимаемых решений.

Научная новизна и практическая ценность

Научная новизна проекта будет заключаться в разработке гибридной архитектуры, сочетающей методы классификации и генерации текста, глубокой специализации на русскоязычных резюме с учетом лингвистических особенностей, адаптации методов трансферного обучения для специфических HR-задач и создании уникальных метрик оценки на основе экспертных данных, получаемых от практикующих HR-специалистов. Особый интерес представляет комбинация различных подходов к обработке естественного языка, что позволяет преодолеть ограничения, присущие отдельным методам. Кроме того, проект предполагает разработку оригинальных методов оценки качества резюме, учитывающих как формальные характеристики, так и содержательные аспекты.

Практическая ценность для соискателей будет состоять в возможности получения мгновенной обратной связи в любое время суток, конкретных рекомендаций по улучшению с примерами и как следствие – повышение шансов на успешное трудоустройство, в то время как для HR-специалистов ценность проявится в значительном сокращении времени на первичный отбор,

стандартизации оценочных процедур и уменьшении влияния человеческого фактора на процесс принятия решений. Образовательный аспект проекта продемонстрирует полный цикл создания ML-продукта, практическую интеграцию нейросетевых технологий в реальное приложение и разработку открытой методологии для последующих исследований в данной области. Особое значение имеет тот факт, что проект будет использовать современные подходы к обработке естественного языка, что представляет интерес с точки зрения развития компьютерной лингвистики.

Дорожная карта проекта будет выстроена вокруг трех фундаментальных компонентов, образующих прочную основу для успешной реализации: данных, модели и инфраструктуры. На первом этапе планируется формирование качественной базы данных через систематический сбор и экспертную разметку русскоязычных резюме с привлечением профессиональных HR-специалистов, что обеспечит репрезентативность данных для последующего обучения модели. Этот этап включает не только сбор данных, но и их тщательную очистку и аннотацию, что является критически важным для достижения высокого качества работы системы.

На следующем этапе будет разрабатываться гибридная архитектура нейросетевой модели, сочетающая анализ контента и генерацию персональных рекомендаций на основе тонкой настройки предобученных моделей с учетом специфики предметной области. Завершающая фаза будет посвящена созданию масштабируемой инфраструктуры с backend API и удобным Telegram-интерфейсом, обеспечивающей доступность и удобство использования системы для конечных пользователей. Каждый этап реализации будет сопровождаться тестированием и валидацией результатов для обеспечения качества разрабатываемого решения.

Перспективы развития

Перспективы развития проекта будут включать расширение функциональности для анализа сопроводительных писем, интеграцию с популярными платформами для поиска работы и разработку системы персонализированных рекомендаций по развитию карьеры на основе анализа накопленных данных о резюме и рыночных трендах. Дальнейшее развитие проекта может быть связано с созданием аналитических инструментов для HR-специалистов, позволяющих отслеживать тенденции на рынке труда и оптимизировать процессы подбора персонала. Долгосрочной перспективой является создание комплексной экосистемы услуг в области управления карьерой и подбора персонала.

Заключение

Таким образом, представленная концепция и архитектура проекта демонстрируют значительный потенциал применения нейросетевых моделей для решения актуальных проблем на современном рынке труда. Разработка системы автоматизированной оценки резюме в Telegram-боте представляет существенный практический интерес и может внести весомый вклад в развитие HR-технологий в русскоязычном сегменте, соответствуя современным тенденциям развития искусственного интеллекта и цифровизации бизнес-

процессов. Комплексный подход к проектированию системы, учитывающий потребности всех заинтересованных сторон, создает предпосылки для успешной реализации проекта и его дальнейшего развития в соответствии с меняющимися требованиями рынка труда и технологическими возможностями. Учет специфики российского рынка труда и языковых особенностей делает проект особенно актуальным в текущих экономических условиях и способствует развитию отечественных технологий в области искусственного интеллекта.

Библиографический список

1. Cappelli, P. Artificial Intelligence in Human Resources Management: Challenges and a Path Forward / P. Cappelli, P. Tambe, V. Yakubovich // SSRN Electronic Journal, 2018. – DOI:[10.2139/ssrn.3263878](https://doi.org/10.2139/ssrn.3263878)
2. Нейронная сеть [Электронный ресурс] // Википедия. – URL: <https://inlnk.ru/4yYlB8> (дата обращения: 20.10.2025).
3. MrDecentralized. Искусственный интеллект на Python с использованием TensorFlow и Keras [Электронный ресурс] / MrDecentralized // Habr. – URL: <https://habr.com/ru/articles/770554/> (дата обращения: 20.10.2025).
4. Зелинов, М. А. Изучение работы нейронных сетей: нейронные сети основы, использование нейронных сетей в экономике / М. А. Зелинов // Гуманитарные науки в современном вузе: вчера, сегодня, завтра : материалы международной научной конференции, Санкт-Петербург, 12 декабря 2019 года / под ред. С. И. Бугашева, А. С. Минина. – Санкт-Петербург: Санкт-Петербургский государственный университет промышленных технологий и дизайна, 2019. – С. 880-885.
5. r1sha. Простой Telegram-бот на Python за 30 минут [Электронный ресурс] / r1sha // Habr. – URL: <http://habr.com/ru/articles/442800/> (дата обращения: 20.10.2025).
6. Уколова, А. В. Эконометрика : практикум / А. В. Уколова, Е. В. Шайкина. – Москва : Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2011. – 105 с. – EDN WEDTMJ.
7. Невзоров, А. С. Прикладные модели и алгоритмы интеллектуального анализа больших данных в сельском хозяйстве / А. С. Невзоров // Материалы международной научно-практической конференции "Тренды развития сельского хозяйства и агрообразования в парадигме Зеленой экономики" : сборник статей, Москва, 14–15 июня 2023 года. – Москва: Российский государственный аграрный университет- Московская сельскохозяйственная академия им. К.А. Тимирязева, 2023. – С. 24-28. – EDN GATIUY.
8. Титов, А. Д. Разработка программного обеспечения по дешифрованию информации / А. Д. Титов, А. Н. Лосев // Электронный сетевой политехнический журнал "Научные труды КубГТУ". – 2020. – № 6. – С. 66-73. – EDN YDFMHQ.
9. Титов, А. Д. Методы и алгоритмы интеллектуального анализа больших данных в сельском хозяйстве / А. Д. Титов // Материалы международной научно-практической конференции "Тренды развития сельского хозяйства и

агрообразования в парадигме Зеленой экономики" : сборник статей, Москва, 14–15 июня 2023 года. – Москва: Российский государственный аграрный университет- Московская сельскохозяйственная академия им. К.А. Тимирязева, 2023. – С. 29-33. – EDN QZGBTG.

10. Храмов, Д. Э. Онтология алгоритмов оценки продолжительности жизненного цикла программного обеспечения / Д. Э. Храмов // Проблемы управления в социально-экономических и технических системах : Материалы XX Международной научно-практической конференции. Сборник научных статей, Саратов, 17–18 апреля 2024 года. – Саратов: Издательский центр "Наука", 2024. – С. 137-140. – EDN RQHOFT.

УДК 004.94:631.5

ПРОГНОЗ УРОЖАЙНОСТИ КУКУРУЗЫ ПО ПОГОДНЫМ ДАННЫМ С ПОМОЩЬЮ НЕЙРОННОЙ СЕТИ НА РУНТОН

Андросова Илона Игоревна, студентка 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, ianderval@mail.ru

Журавлева Юлия Сергеевна, студентка 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, yu.zhh621@mail.ru

Научный руководитель – Титов Артем Денисович, ассистент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, a.titov@rgau-msha.ru

Аннотация. В статье рассмотрен подход к прогнозированию урожайности кукурузы в Московской области на основе анализы метеорологических данных с использованием нейронной сети, реализованной на языке Python. Проведено моделирование зависимости урожайности от погодных факторов, выполнено сравнение фактических и прогнозируемых данных, определена значимость климатических параметров. Полученные результаты демонстрируют эффективность применения технологий искусственного интеллекта в задачах цифровизации сельского хозяйства.

Ключевые слова: прогноз урожайности, кукуруза, нейронная сеть, Python, машинное обучение, погодные данные, агроаналитика, цифровое сельское хозяйство, Московская область.

CORN YIELD FORECASTING FROM WEATHER DATA USING A NEURAL NETWORK IN PYTHON

Ilona Igorevna Androsova, 4th-year student, Institute of Economics and Management of the Agro-Industrial Complex, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, ianderval@mail.ru

Yuliya Sergeevna Zhuravleva, 4th-year student, Institute of Economics and Management of the Agro-Industrial Complex, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, yu.zhhh621@mail.ru

Scientific supervisor – Artem Denisovich Titov, Assistant of the Department of Statistics and Cybernetics, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, a.titov@rgau-msha.ru

Abstract. The article presents an approach to forecasting corn yield in the Moscow region based on the analysis of meteorological data using a neural network implemented in Python. The dependence of yield on weather factors was modeled, a comparison between actual and predicted data was performed, and the significance of climatic parameters was determined. The obtained results demonstrate the effectiveness of artificial intelligence technologies in addressing the challenges of agricultural digitalization.

Keywords: yield forecasting, corn, neural network, Python, machine learning, weather data, agro-analytics, digital agriculture, Moscow region.

Цифровизация агропромышленного комплекса сопровождается активным внедрением систем анализа данных и прогнозирования на основе технологий искусственного интеллекта. Одним из перспективных направлений является прогнозирование урожайности сельскохозяйственных культур с применением нейронных сетей. Точные прогнозы позволяют планировать объемы посевов, оптимизировать агротехнические мероприятия и рационально использовать ресурсы.

Особое значение данная задача имеет для Московской области, где урожайность кукурузы подвержена сильному влиянию погодных условий: температуры, количества осадков, влажности почвы и продолжительности солнечного периода.

Для построения прогностической модели использовались данные Росгидромета и Росстата за 2010-2023 гг. по Московской области. Основными входными параметрами выступали:

1. Среднесуточная температура, °C.
2. Количество осадков, мм.
3. Относительная влажность воздуха, %.
4. Число солнечных часов за месяц.
5. Показатель урожайности кукурузы, ц/га.

На основе этих данных была реализована нейронная сеть в среде Python с использованием библиотек TensorFlow и Keras. Архитектура модели включала:

1. Входной слой с пятью признаками.
2. Два скрытых слоя по 32 нейрона с функцией активации ReLU.
3. Выходной слой с одной нейронной функцией активации linear для прогноза урожайности.

Обучение модели проводилось на 80% данных, оставшиеся 20% использовались для проверки точности. В качестве функции потерь применялось среднеквадратичное отклонение (MSE), оптимизатор – Adam.

В результате обучения нейронная сеть продемонстрировала устойчивую сходимость и высокое качество прогноза. Средняя абсолютная ошибка составила около 3,5 ц/га, а коэффициент детерминации $R^2 = 0,92$, что указывает на высокую степень соответствия прогнозных и фактических данных.

Анализ чувствительности модели показал, что наибольшее влияние на урожайность оказывает средняя температура воздуха и количество осадков в период активной вегетации. Существенное, но менее выраженное влияние отмечено со стороны влажности и продолжительности солнечного периода.

Таким образом, можно сделать вывод, что погодные параметры являются информативной основой для построения моделей прогнозирования урожайности.

Таблица 1

Основные климатические показатели и урожайность кукурузы в Московской области (фрагмент данных)

Год	Температура, °C	Осадки, мм	Влажность, %	Солнечные часы	Урожайность, ц/га
2019	16,2	78	65	212	52,4
2020	17,1	85	67	205	54,8
2021	16,7	93	70	198	49,5
2022	17,3	76	63	223	56,1
2023	18,0	81	66	219	58,4

Таким образом, применение нейронных сетей для прогнозирования урожайности кукурузы на основе погодных данных позволяет достичь высокой точности при минимальных вычислительных затратах. Использование Python как инструмента анализа данных обеспечивает гибкость и возможность адаптации под различные климатические зоны.

Разработанная модель может стать основой для автоматизированных систем поддержки принятия решений в аграрном секторе, что соответствует задачам цифровизации агропромышленного комплекса Российской Федерации. В дальнейшем планируется расширение набора данных и включение дополнительных факторов – характеристик почвы, сортовых особенностей и агротехнических мероприятий.

Библиографический список

1. Гаврилов В. А. Применение методов машинного обучения в прогнозировании урожайности сельскохозяйственных культур / В. А. Гаврилов // Агроинформатика. – 2022. – № 4. – С. 15–22.

2. Россельхозцентр. Статистические данные урожайности кукурузы в регионах РФ [Электронный ресурс]. – Режим доступа: <https://rosselhonzenter.ru> (дата обращения: 15.10.2025).
3. Abadi M., Barham P., Chen J. et al. TensorFlow: Large-scale machine learning on heterogeneous systems [Electronic resource]. – 2016. – URL: <https://www.tensorflow.org> (дата обращения: 15.10.2025).
4. Петров И. А., Киселев Н. Н. Использование искусственных нейронных сетей для анализа климатических данных / И. А. Петров, Н. Н. Киселев // Вестник цифрового АПК. – 2023. – № 2. – С. 47–53.
5. Государственный реестр селекционных достижений, допущенных к использованию : официальное издание. – Москва : Минсельхоз РФ, 2023.
6. Корреляционно-регрессионный анализ влияния экономических факторов на урожайность пшеницы / В. И. Хоружий, Д. В. Быков, А. В. Уколова, А. Г. Ибрагимов // Бухучет в сельском хозяйстве. – 2024. – № 8. – С. 557-571. – DOI 10.33920/sel-11-2408-04. – EDN MMQTOR.
7. Математическая статистика / О. Б. Тарасова, Б. Ш. Дашиева, К. А. Козлов [и др.]. – Москвав : РГАУ-МСХА имени К.А. Тимирязева, Издательство «Научный консультант», 2025. – 130 с. – ISBN 978-5-907933-41-5. – EDN LPNIE.
8. Зинченко, А. П. Анализ инвестиционной деятельности в сельском хозяйстве России в условиях реализации государственных программ / А. П. Зинченко, В. В. Демичев, В. В. Маслакова // Бухучет в сельском хозяйстве. – 2016. – № 9. – С. 70-83. – EDN XDXSTX.
9. Козлов, К. А. Совершенствование системы статистических показателей растениеводства для выборочного наблюдения личных подсобных и других индивидуальных хозяйств граждан / К. А. Козлов // Экономика сельского хозяйства России. – 2023. – № 4. – С. 83-91. – DOI 10.32651/234-83. – EDN KOTKEW.
10. Анализ динамики воспроизводства в сельском хозяйстве России за санкционный период / А. Г. Ибрагимов, В. В. Демичев, В. В. Маслакова [и др.] // Известия Тимирязевской сельскохозяйственной академии. – 2024. – № 5. – С. 153-167. – DOI 10.26897/0021-342X-2024-5-153-167. – EDN TLMDZM.
11. Маслакова, В. В. Статистический анализ эффективности инвестирования в развитие сельского хозяйства в России / В. В. Маслакова, В. В. Демичев. – Москва : Общество с ограниченной ответственностью "Научный консультант", 2021. – 194 с. – ISBN 978-5-907477-08-7. – EDN XZWHNF.
12. Демичев, В. В. Статистическое исследование инвестирования в сельское хозяйство России в условиях реализации государственных программ : монография / В. В. Демичев, В. В. Маслакова. – Иркутск : ООО "Мегапринт", 2017. – 162 с. – ISBN 978-5-907095-19-9. – EDN TUDTFV.

АНАЛИЗ ЗАРУБЕЖНЫХ ИНФОРМАЦИОННЫХ РЕСУРСОВ В КОНТЕКСТЕ ВНЕШНЕЭКОНОМИЧЕСКОЙ ДЕЯТЕЛЬНОСТИ АПК

Анохин Игорь Александрович, ассистент кафедры статистики и кибернетики института экономики и управления АПК ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, anokhin.igor@rgau-msha.ru

Аннотация. В статье проведен анализ зарубежных информационных ресурсов, используемых для исследования внешнеэкономической деятельности субъектов АПК. Работа основана на систематизации официальных открытых источников информации, включая международные организации (FAO, OECD), статистические порталы (Eurostat) и правительственные учреждений (USDA). Для каждого источника уточнены географические рамки данных: FAO охватывает глобальные рынки, OECD фокусируется на развитых странах, Eurostat предоставляет информацию по странам Европейского союза, а USDA специализируется на данных по США и их торговым партнерам. Особое внимание уделено доступности информации для русскоязычных пользователей, а также возможностям получения данных по Российской Федерации, которые оказались ограниченными в большинстве рассматриваемых платформ.

Ключевые слова: информационный ресурс, источник данных, статистический отчет, внешнеэкономическая деятельность, АПК.

ANALYSIS OF FOREIGN INFORMATION RESOURCES IN THE CONTEXT OF FOREIGN ECONOMIC ACTIVITIES OF THE AGRICULTURAL INDUSTRIAL COMPLEX

Anokhin Igor Aleksandrovich, assistant of the Department of Statistics and Cybernetics, Institute of Economics and Management of Agroindustrial Complex of the Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, anokhin.igor@rgau-msha.ru

Annotation. The article analyzes foreign information resources used to study foreign economic activity of agricultural entities. The work is based on the systematization of official open sources of information, including international organizations (FAO, OECD), statistical portals (Eurostat) and government agencies (USDA). For each source, the geographic scope of the data is specified: FAO covers global markets, OECD focuses on developed countries, Eurostat provides information on the countries of the European Union, and USDA specializes in data on the United States and its trading partners. Particular attention is paid to the availability of information for Russian-speaking users, as well as the possibilities of obtaining data on the Russian Federation, which turned out to be limited in most of the platforms under consideration.

Key words: *information resource, data source, statistical report, foreign economic activity, Agro-industrial complex.*

Для обеспечения успешного функционирования хозяйствующих субъектов АПК на мировом рынке необходим доступ к достоверной и актуальной информации, характеризующей торговые потоки, рыночные тенденции и нормативно-правовые условия. «Для получения надежной и полной информации об экспортных и импортных операциях, торговых партнерах, таможенной статистике и других аспектах внешнеэкономической активности субъектов АПК, следует обращаться к разнообразным источникам данных» [1]. Исходя из этого, является предпочтительным рассмотрение международных организаций, статистических порталов, правительственные и национальные ресурсы, которые способны предоставить информацию в области сельского хозяйства и международной торговли.

FAO (Food and Agriculture Organization) является источником надежных данных и аналитических инструментов для статистических исследований в области продовольственной безопасности, сельского хозяйства и мирового продовольственного рынка. Данный иностранный ресурс предоставляет функциональную возможность переключения интерфейса на русский язык, что значительно упрощает взаимодействие с платформой для пользователей из Российской Федерации. Наиболее интересны для исследования разделы: «Новости» и «Статистика» [8]. В новостных публикациях аналитического характера содержится информация, отражающая количественные показатели, индексы и их сравнительный анализ за различные периоды времени. Некоторые статьи дополнены визуализированными статистическими данными, посредством использования графиков и диаграмм, что способствует более наглядному представлению информации для широкого круга лиц. В качестве примера можно привести статью «FAO Food Price Index rises in February», опубликованную 07.03.2025 [8]. В данной публикации отражены результаты мониторинга среднем значении индекса продовольственных цен FAO за февраль. Авторы статьи используют доступный язык для интерпретации данных о значениях данного индекса, который организация рассчитывает ежемесячно (статистическая информация систематизирована и доступна в соответствующем разделе официального сайта FAO) [8]. Здесь приводимые числовые значения индекса за февраль сравниваются авторами со значениями предыдущего месяца, а также раскрываются факторы, обусловившие динамику изменения. Также в данной новостной публикации представлен анализ средних значений индексов цен на отдельные категории продовольственных товаров, включая сахар, молочную продукцию, растительные масла, зерновые культуры и мясо.

Раздел «Статистика» включает в себя несколько подразделов, таких как «Статистика», «Сбор данных» и другие, содержащие информацию о методологических подходах, стандартах и развитии статистического потенциала [8]. Однако одним из ограничений данного раздела для пользователей из Российской Федерации является отсутствие переключения на

русский язык, так как почти все подразделы (исключением является одноименый с самим разделом) доступны исключительно на английском. В подразделе «Статистика» пользователям предоставляется доступ к архиву новостей раздела, а также приведена информация о четырех ключевых базах данных: «FAOSTAT», «SDG Indicators», «AMIS» и «Food and Agriculture Microdata Catalogue (FAM)». FAOSTAT обеспечивает свободный доступ к данным о продовольствии и сельском хозяйстве более чем 245 стран с 1961 года. База данных SDG Indicators предоставляет информацию о 22 показателях, поддерживая страны в оценке прогресса достижения SDG. Межведомственная платформа AMIS (система информационного обеспечения рынков сельскохозяйственной продукции) повышает прозрачность мировых продовольственных рынков, содержит информацию по основным злакам, включая пшеницу, кукурузу, рис и соевые бобы. Каталог микроданных FAM содержит наборы данных опросов фермерских и домашних хозяйств, включающих информацию по сельскому хозяйству, продовольственной безопасности и питанию [8].

Официальный сайт Организации экономического сотрудничества и развития (OECD) предоставляет широкие возможности для анализа статистической информации, в том числе связанной с АПК, однако данный сайт доступен только на английском и французском языках, что создает определенные трудности для русскоязычных пользователей. Не смотря на это, данное ограничение может быть компенсировано за счет простого и удобного функционала платформы, включающего возможность поиска информации по различным категориям, в том числе публикации, данные, новости и события с применением фильтров по языкам (английский или французский), типам контента и тематикам, в том числе по сельскому хозяйству и рыболовству. В частности, на сайте можно найти отчет OECD-FAO Agricultural Outlook 2023-2032, подготовленный совместно OECD и Продовольственной и сельскохозяйственной организацией ООН (FAO), содержащий десятилетний прогноз и анализ тенденций на ключевых международных рынках сельскохозяйственной продукции умеренного климата [7]. Страница раздела Data (Данные) на сайте OECD посвящена предоставлению открытых надежных статистических данных, и меню навигации которой включает следующие категории: Featured (Выделенные ресурсы); Indicators (Индикаторы); Dashboards (Дашборды); Insights (Инсайты); Methods (Методы); Datasets (Датасеты) [7].

UN Comtrade Database предоставляет доступ к детальной информации о мировой торговле, что является основной целью данного ресурса [6]. Возможности платформы включают массовое скачивание данных (требуется премиальная подписка), различные форматы данных и API для интеграции в корпоративные системы, а также инструменты визуализации для анализа больших объемов информации и метаданных [6]. Однако ресурс не содержит данных, непосредственно связанных с сельским хозяйством, ограничиваясь информацией о технике, оборудовании, материалах и ресурсах, применимых в агропромышленном комплексе.

Веб-сайт Eurostat – статистического агентства Европейского союза – предоставляет доступ к официальной статистической информации и аналитическим инструментам, которые охватывают экономические, социальные и демографические показатели стран Европейского Союза, включая информацию о сельском хозяйстве и торговле [3]. Пользователям доступен выбор языка интерфейса: официальный перевод на английский, немецкий и французский языки, а также машинный перевод на 23 языка, включая русский, с предупреждением о возможных неточностях автоматического перевода. Для исследования внешнеэкономического аспекта АПК представляют интерес разделы «Statistical themes», «Database» и «Data visualisations», содержащие тематические данные, структурированные базы и инструменты визуализации [3].

Раздел «Statistical themes» включает основные категории данных, такие как общая и региональная статистика, экономика, демография, промышленность, сельское хозяйство, международная торговля, транспорт, окружающая среда и наука [3]. Особый интерес для исследования представляют категории «Сельское хозяйство» и «Международная торговля». Страница, посвященная сельскому хозяйству, представляет из себя обзорный раздел, в котором доступны данные о структуре ферм, экономических счетах сельского хозяйства, статистике цен на продукцию, производстве, органическом земледелии, плантациях, виноградниках и взаимосвязях с окружающей средой. На странице также размещены последние новости о росте цен на сельхозпродукцию, противоречивых изменениях в прогнозах животноводства. Дополнительно представлены интерактивные материалы для анализа цепочки продовольствия. Страница же «Международной торговли» – обзорный раздел, отражающий статистическую информацию по международной торговле товарами Европейского союза, Европейской ассоциации свободной торговли и стран-кандидатов в члены ЕС [3]. Статистика включает ежемесячные данные по импорту и экспорту, годовые данные о торговых компаниях и торговле по валютам счетов.

Раздел «Database» на сайте Eurostat организован в виде иерархической структуры с раскрывающимся меню, содержащим категории и подкатегории данных (Дерево навигации по данным) [3]. В категории «Подробные наборы данных» располагается подкатегория «Сельское хозяйство», в которой представлены файлы с информацией о ценах продажи сельскохозяйственных товаров по абсолютным значениям и индексам цен, нормированных на различные базовые годы (1995, 2000, 2005, 2015, 2020), для различных типов товаров (зерновые, животноводческая продукция, средства производства) и временных периодов (годовые и месячные данные с 2000 года). Все данные доступны для скачивания в виде таблиц. В подкатегории «Сельское хозяйство» категории «Выбранные наборы данных» представлены данные о ценах на сельскохозяйственные товары и их индексах, включая цены продажи таких товаров, как ячмень, рожь, мягкая пшеница, кукуруза, картофель, сахарная свекла, телята, свиньи, поросыта, овцы, цыплята, свежие яйца и сырое молоко. Также доступны производственные индексы цен на общее

сельскохозяйственное производство, растениеводческие культуры, а также животноводство и продукцию животноводства. Категория «Agri-environmental indicators» содержит данные по аграрно-экологическим показателям, включая площадь под органическим земледелием, продажи пестицидов, долю орошаемых земель, энергоэффективность, выбросы аммиака и парниковых газов от сельского хозяйства, а также оценку потерь почвы от водной эрозии и степень воздействия сильной эрозии на различные типы покрытия земель. Эти показатели организованы по регионам NUTS 2. Каждый показатель представлен в виде ссылок для скачивания данных, а некоторые имеют пометку «UPDATED» (обновлено), указывающую на актуальность информации.

В разделе «Data visualisations» сельскому хозяйству посвящена страница, представляющая из себя интерактивную платформу для создания индивидуальных информационных листов о сельском хозяйстве [3]. Пользователь может выбрать страну или регионы Европейского союза и настроить отображаемые показатели, к примеру, такие как: количество ферм, процент малых и семейных ферм, добавленную стоимость сельского хозяйства и производство зерновых культур.

Веб-сайт Министерства сельского хозяйства США (USDA) является информационным порталом, ориентированным на обеспечение доступа заинтересованным пользователям к ресурсам и поддержке в сферах продовольствия, сельского хозяйства, природных ресурсов, развития сельских территорий и питания, доступный на английском и испанском языках [5]. Служба иностранных сельскохозяйственных отношений (FAS) подчеркивает важность аграрного экспорта для экономики США и фокусируется на оказании поддержки фермерам [5]. На сайте можно найти последние новости и отчеты о международных сельскохозяйственных трендах, к примеру, новостные статьи о регулировании маркировки продуктов питания в Китае, об отчетах о пищевых ингредиентах в Бразилии и других регионах [5]. Раздел «Data and Analysis» на сайте USDA обеспечивает доступ к широкому спектру данных и аналитических инструментов, включая базы данных, приложения, отчеты и визуализации. Здесь отражены ключевые ресурсы, такие как открытые данные FAS (FAS Open Data Services), система запросов по экспортным продажам (Export Sales Query System), онлайн-система PS&D (Production, Supply and Distribution Online), а также глобальная система торговли сельскохозяйственной продукцией GATS (Global Agricultural Trade System) [5].

FAS Open Data Services отражает подробное описание интерфейсов для доступа к данным о еженедельных экспортных продажах сельскохозяйственных товаров США (ESR Data API) и глобальных данных о производстве, поставках и распределении сельскохозяйственных товаров (PSD Data API) [5]. Для работы с API требуется ключ авторизации, который можно получить через Swagger UI. Global Agricultural Trade System содержит статистические данные о торговле сельскохозяйственными, рыбными, лесными и текстильными товарами с 1989 года по настоящее время. Пользователи могут использовать стандартные и расширенные запросы для получения данных, а также работать с API GATS Data. На странице обнародованы последние

новости и обновления, включая доступность отчетов о торговле за февраль 2025 года, такие как обработанные продукты питания, BICO, и общие торговые данные США. Торговый баланс за февраль составил дефицит в размере \$4,270,393,327.00. Система предлагает различные функции, включая визуализацию данных.

US International Trade Administration (ITA) выступает подразделением Министерства торговли США, основным направлением деятельности которого является продвижением экспорта, укрепление конкурентоспособности американских компаний [4]. На сайте, доступном только на английском языке, пользователи могут найти информацию о ежегодных данных о характеристиках экспортаемых товаров, направлениях экспорта, размерах компаний и географической информации через базу данных экспортёров (EDB). Веб-сайт ITA содержит инструменты для анализа национальной и региональной торговли, профилей экспортёров, а также данных о создании рабочих мест.

Страница Visual Data Center (Центр визуализации данных) ITA содержит тематические блоки с визуализацией данных по различным отраслям, включая автомобильную промышленность, энергетику, профессиональные услуги и международную торговлю [4]. Каждый блок сопровождается кратким описанием и ссылкой для получения дополнительной информации. На основе содержания данной страницы, следует отметить, что на ней нет явного упоминания или специфической информации, связанной непосредственно с сельским хозяйством или внешней торговлей сельскохозяйственной продукции.

Страница раздела Production Agriculture ITA посвящена поддержке американских компаний, занимающихся производством сельскохозяйственного оборудования и материалов для выращивания пищи на фермах [4]. Команда специалистов ITA стремится укрепить глобальную конкурентоспособность агропромышленности США и увеличить экспорт, в связи с чем, пользователи могут воспользоваться предлагаемыми услугами исследования рынков, международной консультации по экспорту и глобальной сетью профессионалов торговли. Специалисты агропромышленного направления ITA проводят маркетинговые исследования зарубежных рынков, предоставляя краткие и информативные отчеты. Так к примеру, по запросу «agribusiness» предоставляется 75 результатов, связанных с развитием агробизнеса в различных странах мира. Результаты включают информацию о возможностях в секторе агробизнеса (например, Малайзия, Мексика, Кения), а также данные о профессиональных ассоциациях и публикациях в области агробизнеса США [4]. Пользователи могут использовать фильтры по темам торговли, отраслям и странам для уточнения результатов.

Сайт European Commission – Agriculture and Rural Development – информационный ресурс, освещающий политику и инициативы Европейского союза в сферах сельского хозяйства, развития сельских территорий и аграрной торговли [2]. Доступ к сайту осуществляется на 24 языках, однако русский язык не поддерживается.

Страница «International» на сайте Европейской комиссии посвящена международной торговле сельскохозяйственными товарами и продовольствием,

а также сотрудничеству ЕС с третьими странами и международными организациями [2]. Она содержит информацию о двусторонних торговых соглашениях, сотрудничестве с Африкой, мониторинге рынков и цен на агропродукцию, а также новости и события, связанные с развитием сельского хозяйства. Детализируем два подраздела рассматриваемой страницы, содержимое которых представляет наибольший интерес для исследования. Подраздел «Agricultural markets and prices» включает ежемесячный обзор цен на ключевые аграрные товары и продукты питания, краткие прогнозы для рынков зерновых культур, мяса и молока в Европейского союза, а также серию аналитических материалов о глобальном и европейском аграрном рынке. В подразделе «Trade and international policy analysis» переодически размещаются актуализированные график ежемесячных данных о торговле агропродукцией ЕС, обзор ежегодной торговли с третьими странами, анализ влияния торговых соглашений и последние новости о развитии аграрного сектора.

Раздел «Data and analysis» на сайте Европейской комиссии посвящен актуальной информации о сельскохозяйственных рынках [2]. На странице «Trade data» размещена информация о торговле по отраслям и странам/регионам, данные о торговле ЕС по различным секторам экономики и аналитические материалы о торговле, ценах, объемах и долях основных торговых партнеров ЕС. Подраздел «Trade in value» содержит список стран и регионов, с которыми ЕС осуществляет торговлю агропродукцией, классифицированных по географическим зонам и соглашениям. Переход по ссылке, заложенной в названии каждой страны открывает документ с анализом торговли за 2013–2023 годы, включающий ключевые аграрные и торговые показатели, такие как добавленная стоимость сельского хозяйства, занятость, объемы экспорта и импорта, а также динамику изменения структуры торговли за исследуемый период [2]. Подраздел «Trade by sector» посвящен анализу международной торговли сельскохозяйственными товарами по различным секторам, включая животные продукты (молочные продукты, мясо, свинина, птица и овцы) и растительные продукты (яблоки, цитрусовые, персики,nectарины, томаты, зерновые культуры, масличные и белковые культуры, вино, сахар и рис). Доступна также тарифная и статистическая номенклатура, а балансовые листы представлены в виде таблиц и графиков через портал данных агропродукции.

В результате проведенного исследования были систематизированы и проанализированы зарубежные информационные ресурсы, включая международные организации (FAO, OECD), статистические порталы (Eurostat) и правительственные платформы (USDA), которые предоставляют данные о внешнеэкономической деятельности субъектов агропромышленного комплекса. Особое внимание было уделено открытости доступа на платформах к статистическим данным, аналитическим отчетам и инструментам визуализации, а также функциональным возможностям каждого ресурса, как, к примеру, наличию фильтров для поиска данных по различным категориям. Однако, следует констатировать тот факт, что уровень локализации контента и языковые ограничения могут затруднять использование данных отдельными

категориями пользователей. Полученные результаты подтверждают необходимость комплексного подхода к выбору источников информации.

Библиографический список

1. Анохин, И. А. Анализ информационных ресурсов о внешнеэкономической деятельности субъектов АПК Российской Федерации / И. А. Анохин // Материалы I Национальной научной конференции «Современные направления статистических исследований» : Сборник статей, Москва, 28 декабря 2022 года. – Москва: Российский государственный аграрный университет- Московская сельскохозяйственная академия им. К.А. Тимирязева, 2023. – С. 4-11. – EDN ITYLEU.
2. Agriculture and Rural Development [Электронный ресурс] / European Commission – Режим доступа: https://agriculture.ec.europa.eu/index_en (дата обращения 06.04.2025).
3. Explore Data [Электронный ресурс] / eurostat – Режим доступа: <https://ec.europa.eu/eurostat> (дата обращения 05.04.2025).
4. Trade Data and Analysis [Электронный ресурс] / International Trade Administration – Режим доступа: <https://www.trade.gov> (дата обращения 06.04.2025).
5. USDA [Электронный ресурс] / United States Department of Agriculture – Режим доступа: <https://www.usda.gov> (дата обращения 06.04.2025).
6. База данных статистики международной торговли Организации Объединённых Наций [Электронный ресурс] / UN Comtrade Database – Режим доступа: <https://comtradeplus.un.org> (дата обращения 05.04.2025).
7. Организация экономического сотрудничества и развития [Электронный ресурс] / OECD – Режим доступа: <https://www.oecd.org/en.html> (дата обращения 05.04.2025).
8. Продовольственная и сельскохозяйственная организация Объединенных Наций [Электронный ресурс] / Food and Agriculture Organization – Режим доступа: <https://www.fao.org/home> (дата обращения 05.04.2025).
9. Анохин, И. А. Формирование системы внешнеэкономической безопасности в организациях АПК / И. А. Анохин // Сборник трудов, приуроченных к 75-ой Всероссийской студенческой научно-практической конференции, посвященной 150-летию со дня рождения Е. А. Богданова, Москва, 14–17 марта 2022 года. – Москва: Общество с ограниченной ответственностью "Мегаполис", 2022. – С. 154-157. – EDN BADKZG.
10. Анохин, И. А. Подход к классификации рисков внешнеэкономической деятельности хозяйствующих субъектов агропромышленного комплекса / И. А. Анохин // Вестник ИПБ (Вестник профессиональных бухгалтеров). – 2024. – № 4. – С. 8-13. – DOI 10.51760/2308-9407_2024_4_8. – EDN SGHDVK.
11. Уколова, А. В. Типология личных подсобных хозяйств по данным всероссийской сельскохозяйственной переписи 2016 г / А. В. Уколова, Б. Ш. Дашиева // Экономика и управление: проблемы, решения. – 2022. – Т. 2, № 4(124). – С. 162-172. – DOI 10.36871/ek.up.p.r.2022.04.02.020. – EDN YRPKDV.

12. Дашиева, Б. Ш. Статистическая характеристика сельского хозяйства Республики Бурятия и проблема производительности труда: 2006-2012 г.г / Б. Ш. Дашиева // Вестник Бурятской государственной сельскохозяйственной академии им. В.Р. Филиппова. – 2014. – № 3(36). – С. 111-117. – EDN SMSZTH.

13. Зинченко, А. П. Анализ инвестиционной деятельности в сельском хозяйстве России в условиях реализации государственных программ / А. П. Зинченко, В. В. Демичев, В. В. Маслакова // Бухучет в сельском хозяйстве. – 2016. – № 9. – С. 70-83. – EDN XDXSTX.

14. Оценка инвестиционной привлекательности компаний АПК на основе ESG-факторов / Л. И. Хоружий, Н. А. Трясцин, М. К. Джикя, Н. Ю. Трясцина // Известия Тимирязевской сельскохозяйственной академии. – 2024. – № 2. – С. 189-202. – DOI 10.26897/0021-342X-2024-2-189-202. – EDN MSCLCC.

15. Статистический анализ импортозамещения продукции сельского хозяйства в России / М. В. Кагирова, В. В. Демичев, В. С. Токарев, К. А. Лебедев // Бухучет в сельском хозяйстве. – 2022. – № 7. – С. 514-524. – DOI 10.33920/sel-11-2207-05. – EDN XBWUED.

УДК: 004.8:631

ПЕРСПЕКТИВА ИСПОЛЬЗОВАНИЯ НЕЙРОННЫХ СЕТЕЙ В АПК

Бородкина Елизавета Игоревна, студент 1 курса магистратуры института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, borodckina.elizaveta@yandex.ru

Научные руководители: Хоружий Людмила Ивановна, Д.э.н., профессор кафедры бухгалтерского учета, финансов и налогообложения, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, hli@rgau-msha.ru

Аннотация. В работе производится анализ использования нейронных сетей в АПК. В современном агропромышленном комплексе (АПК) нейронные сети играют ключевую роль в реализации концепций цифрового и точного земледелия. Благодаря способности обрабатывать большие объемы данных и выявлять сложные зависимости, нейросетевые алгоритмы обеспечивают качественный прорыв в управлении сельскохозяйственными процессами.

Ключевые слова: нейронные сети, АПК, цифровой анализ.

PROSPECTS FOR USING NEURAL NETWORKS IN THE AGRO-INDUSTRIAL COMPLEX

Borodkina Elizaveta Igorevna, 1st-year master's student at the Institute of Economics and Management of the Agro-Industrial Complex, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, borodckina.elizaveta@yandex.ru

Lyudmila Ivanovna Khoruzhiy, Doctor of Economics, Professor, Department of Accounting, Finance, and Taxation, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, hli@rgau-msha.ru

Annotation. *The paper analyzes the use of neural networks in agriculture. In the modern agro-industrial complex, neural networks play a key role in the implementation of digital and precision farming concepts. Due to the ability to process large amounts of data and identify complex dependencies, neural network algorithms provide a qualitative breakthrough in agricultural process management.*

Key words: neural networks, agroindustrial complex, digital analysis.

Одним из наиболее востребованных направлений является использование сверточных нейронных сетей (CNN) для анализа изображений с беспилотных летательных аппаратов (БПЛА) и спутников. Эти модели позволяют оперативно выявлять признаки заболеваний и стрессовых состояний растений, а также оценивать степень засоренности поля сорняками. Например, интеграция CNN с мультиспектральными и гиперспектральными камерами дает возможность классифицировать типы заболеваний с точностью более 90%, что значительно превосходит традиционные методы визуального контроля.

Кроме того, рекуррентные нейронные сети (RNN), включая их разновидности – LSTM и GRU, используются для прогнозирования урожайности и погодных условий на основе временных рядов данных. Такие модели помогают агропредприятиям адаптировать агротехнологии под динамические изменения климата и снижать риски, связанные с экстремальными погодными явлениями.

Технологии глубокого обучения также находят применение в роботизированных системах сбора урожая. Примером служат автономные комбайны и манипуляторы, оснащённые нейросетевыми системами распознавания и сортировки плодов по степени зрелости и качеству. Это не только повышает производительность труда, но и минимизирует потери продукции.

Для эффективного использования нейронных сетей необходимы масштабные датасеты, включающие данные о почвах, климате, генотипах растений и технологических операциях. В этом контексте важную роль играют платформы сбора и анализа данных на базе облачных технологий и IoT-инфраструктуры. Современные решения по интеграции AI-моделей с облачными вычислениями позволяют агропредприятиям оперативно принимать решения на основе анализа больших данных в режиме реального времени.

Вызовом для внедрения нейросетевых технологий остается необходимость создания стандартизованных протоколов обработки данных и обеспечения кибербезопасности аграрных информационных систем. Также критически важна подготовка специалистов в области агроинформатики, способных разрабатывать и внедрять современные AI-решения.

Таким образом, перспективы развития нейронных сетей в АПК обусловлены ростом вычислительных мощностей, доступностью качественных

данных и интеграцией с цифровыми платформами. Эти технологии создают фундамент для формирования умного сельского хозяйства, способного повысить урожайность, снизить издержки и обеспечить устойчивое развитие агропромышленного комплекса.

Библиографический список

1. Васильев А.Н. Принципы и техника нейросетевого моделирования / А.Н. Васильев,
2. Галушкин А.И. Нейронные сети: основы теории. / А.И. Галушкин. М.: РиС, 2015.
3. Редько В.Г. Эволюция, нейронные сети, интеллект: Модели и концепции эволюционной кибернетики / В.Г. Редько. М.: Ленанд, 2019. 224 с
4. Романцева, Ю. Н. Автоматизация анализа и прогнозирования развития аграрного сектора региона в среде r / Ю. Н. Романцева, А. М. Бодур, А. Б. Малина // Инфокоммуникационные технологии. – 2024. – Т. 22, № 2(86). – С. 94-102. – DOI 10.18469/ikt.2024.22.2.10. – EDN HEMORD.
5. Цифровые технологии в сельском хозяйстве / В. И. Хоружий, А. В. Уколова, В. В. Демичев [и др.]. – Москва : Российский государственный аграрный университет, 2024. – 234 с. – ISBN 978-5-9675-2056-3. – EDN FZBLXE.
6. Оценка инвестиционной привлекательности компаний АПК на основе ESG-факторов / Л. И. Хоружий, Н. А. Трясцин, М. К. Джикия, Н. Ю. Трясцина // Известия Тимирязевской сельскохозяйственной академии. – 2024. – № 2. – С. 189-202. – DOI 10.26897/0021-342X-2024-2-189-202. – EDN MSCLCC.
7. Невзоров, А. С. Прикладные модели и алгоритмы интеллектуального анализа больших данных в сельском хозяйстве / А. С. Невзоров // Материалы международной научно-практической конференции "Тренды развития сельского хозяйства и агрообразования в парадигме Зеленой экономики" : сборник статей, Москва, 14–15 июня 2023 года. – Москва: Российской государственный аграрный университет- Московская сельскохозяйственная академия им. К.А. Тимирязева, 2023. – С. 24-28. – EDN GATIUY.
8. Токарев, В. С. Социально-экологическая трансформация сельского хозяйства России / В. С. Токарев, В. В. Демичев // Московский экономический журнал. – 2023. – Т. 8, № 6. – DOI 10.55186/2413046X_2023_8_6_261. – EDN YDBFDL.
9. Маслакова, В. В. Анализ социально-экологических трансформаций в сельском хозяйстве России / В. В. Маслакова, В. С. Токарев // Бухучет в сельском хозяйстве. – 2024. – № 5. – С. 325-338. – DOI 10.33920/sel-11-2405-03. – EDN QMKXWS.
10. Горшкова, Д. А. Анализ системы показателей целей устойчивого развития / Д. А. Горшкова // Материалы II национальной научной конференции "Современные направления статистических исследований", Москва, 26 декабря 2023 года. – Москва: Российской государственный аграрный университет, 2024. – С. 122-130. – EDN APKNRM.

УДК 004.8

ВЛИЯНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ВЕБ-РАЗРАБОТКУ

Британова Анна Андреевна, студентка 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, brit2607@mail.ru

Шапошникова Екатерина Евгеньевна, студентка 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, katerinasha09@gmail.com

Научный руководитель – Демичев Вадим Владимирович, к.э.н., доцент, доцент кафедры статистики и кибернетики ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева

Аннотация: В статье рассматривается влияние искусственного интеллекта на frontend-разработку и backend-разработку. Также описываются различные инструменты со встроенным искусственным интеллектом, используемые в веб-разработке.

Ключевые слова: искусственный интеллект, веб-разработка

THE IMPACT OF ARTIFICIAL INTELLIGENCE ON WEB DEVELOPMENT

Britanova Anna Andreevna, 4th-year student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU-MSHA), brit2607@mail.ru

Shaposhnikova Ekaterina Evgenyevna, 4th-year student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU-MSHA), katerinasha09@gmail.com

Scientific Supervisor – Demichev Vadim Vladimirovich, Candidate of Economic Sciences, Associate Professor, Department of Statistics and Cybernetics, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU-MSHA)

Abstract: The article examines the impact of artificial intelligence on both frontend and backend web development. It also describes various AI-powered tools currently used in web development.

Keywords: artificial intelligence, web development

Искусственный интеллект (ИИ) – это технология, которая занимается разработкой алгоритмов, способных выполнять задачи, требующие

интеллектуальных способностей, присущих человеку. Основная цель ИИ – не замена человека, а его усиление, освобождение от рутины и предоставление интеллектуальных инструментов для решения сложных проблем. Для работы с ИИ очень важно уметь правильно и чётко описывать задачу.

Искусственный интеллект проникает во все сферы нашей жизни, начиная от простых бытовых вопросов и заканчивая помощью в создании целых приложений. Это и не обошло стороной разработку веб-сайтов.

Автоматизация рабочего процесса с помощью искусственного интеллекта решает базовые задачи дизайнеров, что позволяет им тратить меньше времени на рутину и больше на творчество и продумывание удобства сайта для пользователей. Ярким примером являются AI-функции в Figma.

Figma – это онлайн-сервис для разработки интерфейсов и прототипирования веб-сайтов и приложений. Функции Figma AI: Figma Sites (конструктор для создания сайтов), Figma Make (сервис, преобразовывающий текст в код), Figma Buzz (инструмент для маркетологов), Figma Draw (редактор для векторных иллюстраций).

Функция Figma Sites полезна в веб-дизайне. Веб-дизайн – это разработка пользовательского интерфейса сайтов и приложений, которая включает в себя как визуальные аспекты (цвета, шрифты, картинки и оформление), так и функциональные (навигация, кнопки, формы, расположение и д.р.). В конструкторе Figma Sites есть заранее настроенные макеты, блоки и шаблоны, так же можно добавлять переходы, анимации и эффекты прокрутки.

Одной из самых многообещающих областей применения ИИ в веб-разработке является автоматическая генерация качественного фронтенд-кода напрямую из готовых дизайн-макетов.

В сервисе Figma этот процесс реализован через специализированные плагины, такие как Anima, Locofy и другие. Эти инструменты используют модели машинного обучения для анализа макета и его преобразования в готовые шаблоны на HTML, CSS, JavaScript.

Принцип работы можно разделить на три этапа:

1. Восприятие – ИИ-алгоритм «осматривает» фрейм Figma, сканируя все его элементы (кнопки, текстовые блоки, изображения и формы).

2. Анализ – система определяет свойства каждого элемента (размеры, позицию, шрифты, цвета, отступы и эффекты).

3. Трансляция – на основе этого анализа ИИ генерирует соответствующий код.

Преимущества автоматизированной верстки – сокращение времени работы, минимизация человеческих ошибок и единообразие кода.

По сравнению с предыдущими этапами веб-разработки, влияние искусственного интеллекта на backend-процессы остается менее заметным, но не менее значимым. В backend-разработке ИИ применяется в тестировании, отладке, аналитике и оптимизации.

Преимуществами использования ИИ в этой области являются: ускорение разработки, улучшение процессов тестирования, повышение качества и безопасности кода.

На практике мы проверили, как влияет информативность и детальность промта на соответствие техническому заданию по разработке веб-сайта, и насколько сильно будут отличаться результаты, полученные от двух разных промтов. Промт – это текстовый запрос для нейросети, который определяет, какую задачу ей нужно выполнить.

ТЗ: разработать сайт для агропромышленной компании, специализирующейся на производстве молока и молочной продукции. Должна присутствовать главная страница, страница с продукцией и страница с контактной информацией. Стилистика сайта должна соответствовать деятельности организации.

В качестве детализированного промта мы написали текст, развернуто описывающий все аспекты будущего сайта – тематику, общий стиль сайта, логотип, шрифт, цветовую гамму, желаемые изображения, наличие конкретных страниц и кнопок, а также подписей к ним. В обычном коротком промте мы написали лишь деятельность компании и необходимые страницы. Результаты представлены на рисунках:

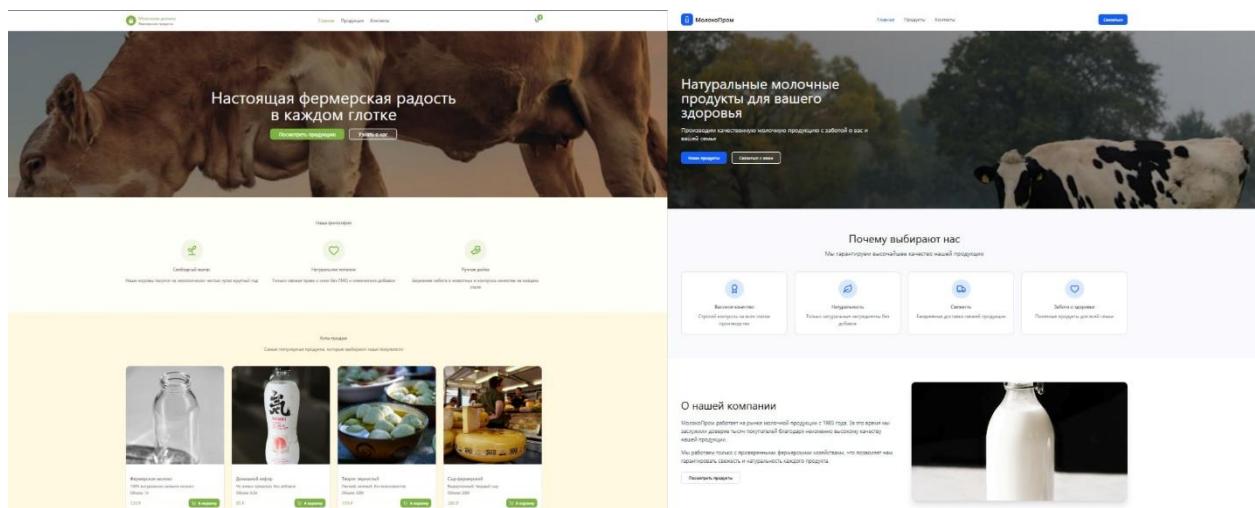


Рисунок 1 – Результаты генерации веб-страниц

Как можно заметить, сайты по обоим промтам по своей форме получились схожие, однако в первом варианте были учтены все запросы по оформлению и общему стилю.

На основе полученных результатов мы увидели, что у ИИ есть встроенные шаблоны общей формы сайта (из-за чего полученный результат не будет уникальным), при этом, по требованию пользователя, он может добавлять желаемые детали и функции в необходимые места.

Проведенный анализ демонстрирует, что искусственный интеллект – это рабочий инструмент и ассистент специалистов, который в разы ускоряет работу, путем выполнения рутинных задач. ИИ – это не полноценная замена человеческого труда, а ее усилитель, и в будущем ценность специалиста будет определяться стратегическим мышлением, креативностью и навыком управления ИИ-инструментами.

Библиографический список:

1. Figma AI – ваш творческий соратник. [Электронный ресурс]. – Режим доступа: <https://www.figma.com/ai/?ysclid=mh6h8f0rzq177217118> – Заглавие с экрана. – (Дата обращения 14.10.2025).
2. Figma. [Электронный ресурс]. – Режим доступа: <https://www.figma.com/> – Заглавие с экрана. – (Дата обращения 14.10.2025).
3. Figma Make. [Электронный ресурс]. – Режим доступа: <https://www.figma.com/make/> – Заглавие с экрана. – (Дата обращения 14.10.2025).
4. Нейросети для дизайнера [Электронный ресурс]. – Режим доступа: <https://practicum.yandex.ru/blog/top-neurosetey-dlya-dizaynerov/?ysclid=mgp8b6xvk3214443130>. – Заглавие с экрана. – (Дата обращения 14.10.2025).
5. Романцева, Ю. Н. Цифровые решения для расчета углеродного следа в сельском хозяйстве / Ю. Н. Романцева, А. М. Бодур // Экономика и управление: проблемы, решения. – 2024. – Т. 15, № 11(152). – С. 150-159. – DOI 10.36871/ek.up.p.r.2024.11.15.021. – EDN PIBJXJ.
6. Ветошкин, А. Ю. Опыт реализации программ профессиональной переподготовки в аграрном вузе в рамках проекта "Цифровые кафедры" / А. Ю. Ветошкин // Всемирный день качества – 2023 : Материалы IV Международной конференции, Саратов, 08 ноября 2023 года. – Саратов: Саратовский государственный медицинский университет им. В.И. Разумовского, 2023. – С. 78-85. – EDN EOWDGA.
7. Ветошкин, А. Ю. Разработка веб-сайта "#Тиморганик" для популяризации органической продукции / А. Ю. Ветошкин // Материалы международной научно-практической конференции "Тренды развития сельского хозяйства и агрообразования в парадигме Зеленой экономики" : сборник статей, Москва, 14–15 июня 2023 года. – Москва: Российский государственный аграрный университет- Московская сельскохозяйственная академия им. К.А. Тимирязева, 2023. – С. 12-17. – EDN JBORIL.
8. Романцева, Ю. Н. Разработка мобильного приложения для сканирования молочной продукции / Ю. Н. Романцева, А. С. Невзоров // Цифровые технологии анализа данных в сельском хозяйстве. – Москва : «Научный консультант», 2022. – С. 128-178. – EDN PKQVSS.
9. Харитонова, А. Е. Разработка модуля информационной системы распознавания образов / А. Е. Харитонова, А. Д. Титов // Цифровые технологии анализа данных в сельском хозяйстве. – Москва : «Научный консультант», 2022. – С. 211-241. – EDN CRKOMW.
10. Храмов, Д. Э. Цифровые ресурсы как инструмент педагогики автономии в высшей школе / Д. Э. Храмов // Педагогическое взаимодействие: возможности и перспективы : Материалы VI международной научно-практической конференции, Саратов, 28–30 марта 2024 года. – Саратов: Саратовский государственный медицинский университет им. В.И. Разумовского, 2024. – С. 441-445. – EDN SIXVWL.

11. Свидетельство о государственной регистрации программы для ЭВМ № 2023683324 Российской Федерации. «Система управления веб-сайтом для реализации органических кормов для животных» : № 2023682448 : заявл. 26.10.2023 : опубл. 07.11.2023 / Н. Ф. Зарук, М. В. Кагирова, Ю. Н. Романцева [и др.] ; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет - МСХА имени К.А. Тимирязева». – EDN IBTKLC.

12. Кагирова, М. В. Расширение сегмента потребителей органической продукции сельского хозяйства с использованием информационных технологий / М. В. Кагирова, Ю. Н. Романцева, С. О. Семенова // International Agricultural Journal. – 2023. – Т. 66, № 4. – DOI 10.55186/25876740_2023_7_4_5. – EDN GOPRME.

13. Семенова, С. О. Разработка web-приложения для реализации натуральных кормов / С. О. Семенова // Столыпинский вестник. – 2023. – Т. 5, № 8. – DOI 10.55186/27131424_2023_5_8_7. – EDN CCUEFW.

УДК 004.8

ОБНАРУЖЕНИЕ АНОМАЛИЙ НА ОСНОВЕ ПОЛНОСВЯЗНОЙ НЕЙРОННОЙ СЕТИ АВТОЭНКОДЕРНОГО ТИПА

Бычкова Мария Антоновна, студентка 2 курса института экономики и управления АПК ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, mariabychkova77@gmail.com

Научный руководитель – Анохин Игорь Александрович, ассистент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, anokhin.igor@rgau-msha.ru

Аннотация. В статье рассматривается применение полносвязной нейронной сети автоэнкодерного типа для решения задачи обнаружения аномалий в условиях отсутствия размеченных аномальных данных. Автор демонстрирует эффективность подхода на примере датасета MNIST в постановке one-class classification. Особое внимание уделено архитектуре автоэнкодера, критерию выявления аномалий на основе ошибки реконструкции и оценке качества модели. Цель работы – показать, что даже простая архитектура без учителя способна обеспечить сбалансированное обнаружение аномалий с минимальным числом ложных срабатываний.

Ключевые слова: нейронная сеть, автоэнкодер, обнаружение аномалий, one-class classification, машинное обучение, Python.

ANOMALY DETECTION BASED ON A FULLY CONNECTED AUTOENCODER-TYPE NEURAL NETWORK

Bychkova Maria Antonovna, 2st year student of the Institute of Economics and Management of Agroindustrial Complex of the Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, mariabychkova77@gmail.com

Scientific supervisor – Anokhin Igor Aleksandrovich, assistant of the Department of Statistics and Cybernetics, of the Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, anokhin.igor@rgau-msha.ru

Annotation. *The article explores the use of a fully connected autoencoder-type neural network to address the anomaly detection problem in the absence of labeled anomalous data. The author demonstrates the effectiveness of the approach using the MNIST dataset under a one-class classification setting. Particular attention is paid to the autoencoder architecture, the reconstruction error-based anomaly detection criterion, and model performance evaluation. The study aims to show that even a simple unsupervised architecture can achieve balanced anomaly detection with minimal false positives.*

Key words: *neural network, autoencoder, anomaly detection, one-class classification, machine learning, Python.*

Актуальность темы обусловлена растущей потребностью в методах обнаружения аномалий в таких областях, как промышленный контроль качества, кибербезопасность и медицинская диагностика [1, 2]. В этих задачах аномальные случаи, как правило, крайне редки и не размечены, что делает традиционные методы классификации с учителем неприменимыми. В таких условиях особенно ценными становятся подходы обучения без учителя, среди которых выделяются автоэнкодеры – нейронные сети, способные выявлять отклонения через анализ ошибки реконструкции входных данных [3].

В работе используется полносвязная нейронная сеть автоэнкодерного типа. Архитектура состоит из энкодера и декодера, симметричных относительно узкого латентного слоя [4]. Конкретно: входной слой (784 нейрона, соответствует развернутому изображению 28×28), скрытые слои энкодера (128 и 64 нейрона с активацией ReLU), и симметричный декодер с сигмоидной активацией на выходе. Обучение проводилось с использованием оптимизатора Adam и функции потерь MSE (среднеквадратичная ошибка).

Эксперимент проводился в постановке one-class classification: модель обучалась исключительно на изображениях цифры «7» из датасета MNIST. После обучения ошибка реконструкции для каждого изображения вычислялась как MSE между исходным и восстановленным изображением. Порог аномальности был установлен на уровне 95-го перцентиля ошибок реконструкции обучающей выборки. Любое изображение с ошибкой выше этого порога классифицировалось как аномалия.

Результаты оказались впечатляющими:

- Полнота аномалий (доля корректно выявленных не-»семёрок») составила 87,47 %;
- Точность нормы (доля корректно распознанных «семёрок») – 92,02 %.

Это свидетельствует о сбалансированной работе модели и низком уровне ложных срабатываний – критически важном свойстве для практических применений.

Таким образом, даже простая полносвязная архитектура автоэнкодера способна эффективно решать задачи обнаружения аномалий без необходимости в разметке аномального класса. Подход особенно перспективен для one-class задач и может быть адаптирован под реальные промышленные или медицинские данные. В дальнейшем планируется переход к свёрточным автоэнкодерам и тестирование на специализированных промышленных датасетах для повышения качества реконструкции и обобщающей способности модели.

Библиографический список

1. Научный форум: Экономика, управление и цифровые технологии в АПК-2024 : Сборник трудов, приуроченных к Международной научно-практической студенческой конференции, Москва, 20 ноября 2024 года. – Москва: Российский государственный аграрный университет, 2024. – 488 с. – ISBN 978-5-9675-2048-8. – EDN CKWNQW.

2. Свидетельство о государственной регистрации программы для ЭВМ № 2024690429 Российской Федерации. «Программное средство для верификации личностей пользователей во время ВКС с использованием методов искусственного интеллекта» : № 202468865 : заявл. 29.11.2024 : опубл. 16.12.2024 / А. Д. Титов, В. В. Демичев, Д. Э. Храмов [и др.] ; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева». – EDN INWDCO.

3. Свидетельство о государственной регистрации программы для ЭВМ № 2023687562 Российской Федерации. Многомодельные автоэнкодеры : № 2023687276 : заявл. 12.12.2023 : опубл. 18.12.2023 / А. А. Шамей. – EDN DZPQBU.

4. Imashev, S. A. Method for detecting anomalies in geomagnetic field variations based on artificial neural network / S. A. Imashev // Geosystems of Transition Zones. – 2024. – Vol. 8, No. 4. – P. 343-356. – DOI 10.30730/gtrz.2024.8.4.343-356. – EDN FHZSKV.

5. Анохин, И. А. Подход к классификации рисков внешнеэкономической деятельности хозяйствующих субъектов агропромышленного комплекса / И. А. Анохин // Вестник ИПБ (Вестник профессиональных бухгалтеров). – 2024. – № 4. – С. 8-13. – DOI 10.51760/2308-9407_2024_4_8. – EDN SGHDVK.

6. Титов, А. Д. Разработка программного обеспечения по дешифрованию информации / А. Д. Титов, А. Н. Лосев // Электронный сетевой

политематический журнал "Научные труды КубГТУ". – 2020. – № 6. – С. 66-73.
– EDN YDFMHQ.

УДК 004.8

ИНТЕЛЛЕКТУАЛЬНЫЙ АССИСТЕНТ ДЛЯ СТУДЕНТА НА PYTHON: ИННОВАЦИОННОЕ РЕШЕНИЕ ДЛЯ СОВРЕМЕННОГО ОБРАЗОВАНИЯ

Галимуллин Данил Рамильевич, студент 4 курса бакалавриата института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, [danil.frompayday@gmail.com](mailto:daniel.frompayday@gmail.com)

Нечаев Артемий Сергеевич, студент 4 курса бакалавриата института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, nechaevas_tm@mail.ru

Научный руководитель: Токарев Виктор Сергеевич, старший преподаватель кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, victokarev@rgau-msha.ru

Аннотация. В статье рассматривается опыт разработки и внедрения интеллектуального ассистента для студентов на Python, использующего передовые технологии распознавания речи OpenAI Whisper и интеллектуального резюмирования текстов с применением модели ruT5. Основной целью проекта стало повышение доступности образования и оптимизация учебного процесса за счёт автоматизации транскрипции лекций и создания структурированных конспектов с использованием графического интерфейса Tkinter.

Ключевые слова: искусственный интеллект в образовании, распознавание речи, резюмирование текстов, OpenAI Whisper, ruT5, Tkinter, Python, персонализированное обучение.

INTELLIGENT ASSISTANT FOR STUDENTS ON PYTHON: AN INNOVATIVE SOLUTION FOR MODERN EDUCATION

Danil Ramil'evich Galimullin, 4th year undergraduate student of the Institute of Economics and Management of the Agro-industrial Complex, K. A. Timiryazev Moscow State Agricultural Academy, [danil.frompayday@gmail.com](mailto:daniel.frompayday@gmail.com)

Artemiy Sergeevich Nечаев, 4th year undergraduate student of the Institute of Economics and Management of the Agro-industrial Complex, K. A. Timiryazev Moscow State Agricultural Academy, nechaevas_tm@mail.ru

Scientific supervisor: Tokarev Viktor Sergeevich, senior lecturer of the Statistics and Cybernetics Department, K. A. Timiryazev Moscow State Agricultural Academy, victokarev@rgau-msha.ru

Annotation. The article discusses the experience of developing and implementing an intelligent assistant for students on Python, using advanced speech recognition technologies OpenAI Whisper and intelligent text summarization using the ruT5 model. The main goal of the project was to increase the accessibility of education and optimize the learning process through the automation of lecture transcription and the creation of structured notes using a Tkinter graphical interface.

Keywords: artificial intelligence in education, speech recognition, text summarization, OpenAI Whisper, ruT5, Tkinter, Python, personalized learning.

Современное высшее образование в России требует инновационных решений для повышения качества и доступности обучения. Традиционное конспектирование лекций создает когнитивную перегрузку – студенты одновременно слушают, анализируют и записывают информацию, часто упуская важные смысловые связи. Студенты с ограниченными возможностями здоровья испытывают особые затруднения при традиционных методах обучения.

Разработанная система интеллектуального ассистента автоматизирует транскрипцию лекций и создание структурированных конспектов. Система объединяет три технологии: распознавание речи OpenAI Whisper, резюмирование текстов ruT5 и графический интерфейс Tkinter (Рисунок 1), позволяя студентам сосредоточиться на понимании материала.

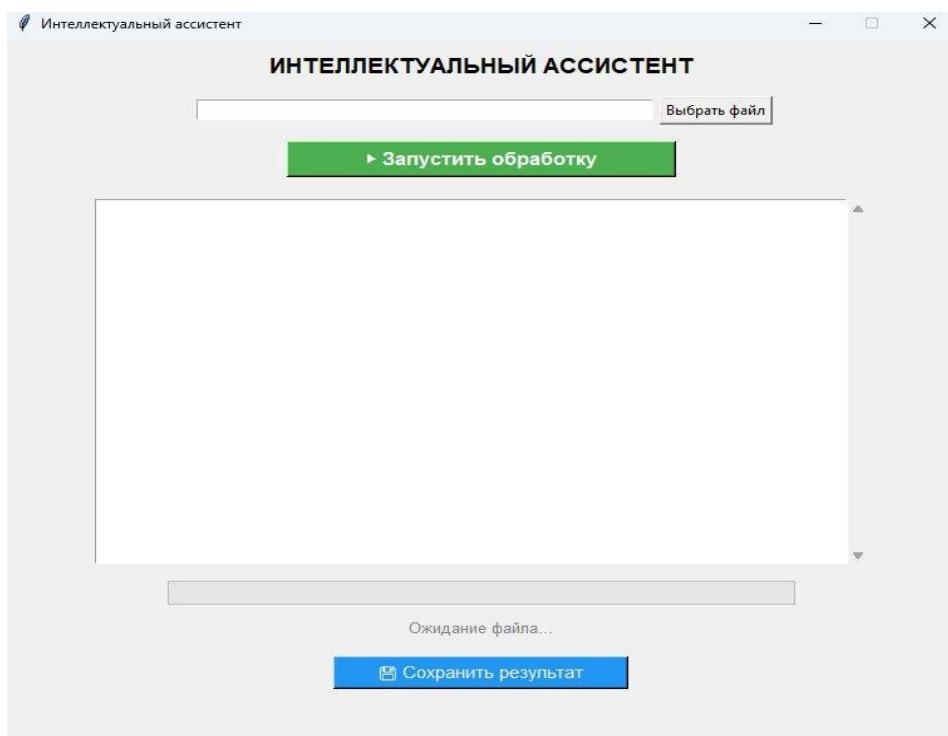


Рисунок 1 – Интерфейс приложения

OpenAI Whisper обеспечивает распознавание речи, обученная на 680,000 часах аудиоконтента. Модель использует архитектуру encoder-decoder transformer с 12 блоками, эффективно обрабатывая 30-секундные сегменты и обеспечивая точность при различных акцентах и аудиторном шуме.

Модель ruT5-base адаптирована для русского языка на датасете из 60,000 образцов. Она создает абстрактивные резюме, генерируя новые формулировки и сохраняя смысл оригинального контента.

Tkinter предоставляет кроссплатформенный интерфейс на Windows, macOS и Linux с элементами выбора файлов, индикаторами прогресса и интерактивными кнопками управления.

Система реализует двухэтапную обработку. Whisper транскрибирует аудио (см. рис. 2), разбивая его на 30-секундные сегменты. Затем для коротких текстов применяется extractive резюмирование с ключевыми фразами, для длинных – ruT5 создает abstractive резюме через beam search, балансируя полноту и краткость.

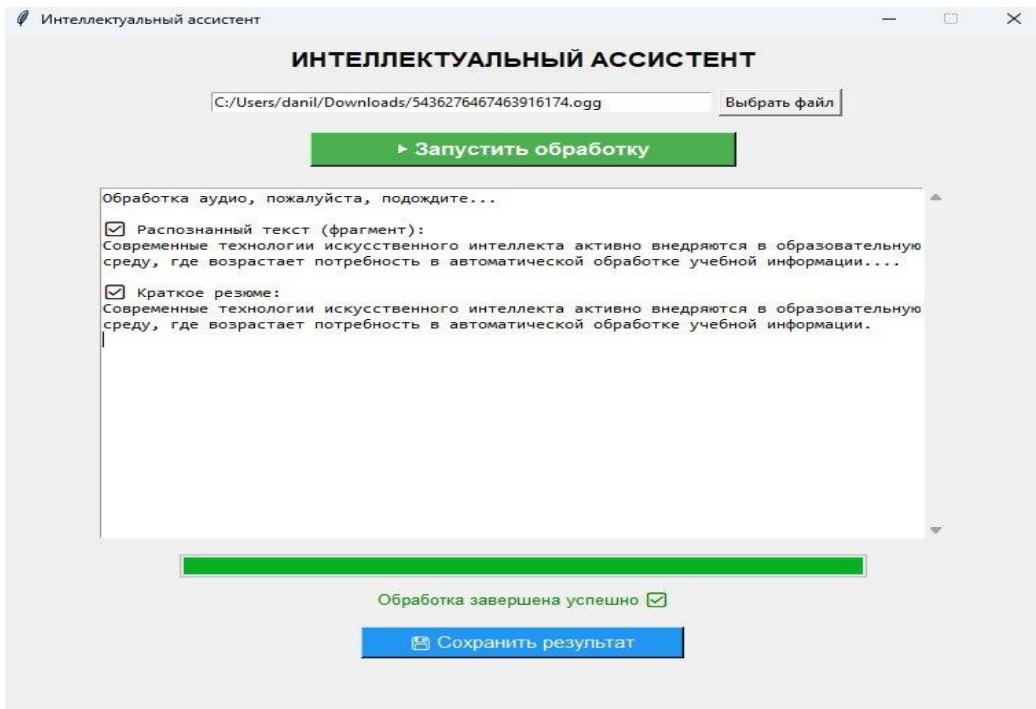


Рисунок 2 – Результат работы приложения

Технологии распознавания речи улучшают доступность для студентов с ограниченными возможностями. Студенты с нарушениями слуха получают текстовые транскрипции, с моторными нарушениями – голосовое управление. Исследования показывают, что 90% студентов отмечают улучшение понимания материала при использовании подобных технологий.

ИИ-ассистенты снижают рабочую нагрузку преподавателей на 4-5 раз в подготовке материалов. Автоматизация транскрипции позволяет студентам сосредоточиться на анализе, существенно повышая качество усвоения. Студенты, использующие ИИ для резюмирования, сокращают время изучения до 50% без снижения успеваемости.

Система полностью поддерживает русский язык на всех этапах обработки, что критично для российских вузов. Whisper демонстрирует высокую точность распознавания с различными акцентами в условиях аудиторного шума.

Опрос 52,919 российских студентов показал растущий интерес к ИИ в образовании. МГУ имени М.В. Ломоносова, НИУ ВШЭ и другие ведущие вузы используют подобные системы для персонализированных траекторий и автоматизации администрирования.

Приложение легко интегрируется в учебный процесс. Студенты записывают лекции на смартфон, загружают файлы и получают конспекты за несколько минут. Многопоточная архитектура обеспечивает отзывчивость при обработке длинных записей, прогресс-бар информирует о текущем состоянии.

Уникальной особенностью является adaptive summarization – автоматический выбор метода резюмирования по длине текста, обеспечивая качество при минимальных затратах ресурсов.

Система включает comprehensive error handling для сбоев: отсутствие файла, проблемы загрузки модели, ошибки обработки. Fallback mechanism гарантирует результат при сбое ruT5, используя альтернативные методы.

Функция сохранения экспортирует полный транскрипт и резюме в текстовый файл для долгосрочного использования при подготовке к экзаменам и написании работ.

Представленный ассистент демонстрирует успешную интеграцию ИИ в образовательный процесс российских вузов. Сочетание Whisper, ruT5 и Tkinter создает мощный инструмент для цифровой трансформации образования.

Система адресует потребности российского образования: поддержку русского языка, обеспечение доступности для студентов с ограниченными возможностями, оптимизацию учебного процесса. Гибридный подход обеспечивает качество при эффективном использовании ресурсов.

Развитие таких технологий открывает перспективы персонализированного и инклюзивного образования. По мере совершенствования ИИ-моделей такие ассистенты станут неотъемлемой частью образовательного процесса в российских университетах.

Библиографический список

1. OpenAI. Whisper: Robust Speech Recognition via Large-Scale Weak Supervision. [Электронный ресурс]. –

Режим доступа: <https://openai.com/research/whisper> (дата обращения: октябрь 2025). Тип – электронный.

2. Transformers library documentation. [Электронный ресурс]. -- Режим доступа: <https://huggingface.co/docs/transformers/> (дата обращения: октябрь 2025). Тип – электронный.

3. ruT5 Model for Russian Text Summarization. [Электронный ресурс]. -- Режим доступа: <https://huggingface.co/cointegrated/rut5-base> (дата обращения: октябрь 2025). Тип – электронный.

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В МЕДИЦИНСКОЙ ДИАГНОСТИКЕ

Голубев Алдар Саналович, студент 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, aldargolybeb@gmail.com

Савельев Антон Равильевич, студент 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, arsavelyev3009@gmail.com

Научный Руководитель – Демичев Вадим Владимирович, к.э.н., доцент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, demichev_v@rgau-msha.ru

Аннотация. Статья посвящена применению нейронных сетей в медицинской диагностике, включая анализ изображений, прогнозирование заболеваний и разработку лекарств. Рассматриваются реальные примеры внедрения технологий искусственного интеллекта в клиническую практику и основные challenges, связанные с их использованием

Ключевые слова: нейронные сети, медицинская диагностика, искусственный интеллект, машинное обучение, компьютерное зрение, диагностические системы

APPLICATION OF NEURAL NETWORKS IN MEDICAL DIAGNOSTICS

Aldar Sanalovich Golubev, 4th-year student, Institute of Economics and Management in the Agro-Industrial Complex, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), aldargolybeb@gmail.com

Anton Ravilevich Saveliev, 4th-year student, Institute of Economics and Management in the Agro-Industrial Complex, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), arsavelyev3009@gmail.com

Scientific Supervisor: Vadim Vladimirovich Demichev, Candidate of Economic Sciences, Associate Professor, Department of Statistics and Cybernetics, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), demichev_v@rgau-msha.ru

Abstract. The article addresses the application of neural networks in medical diagnostics, including medical image analysis, disease prediction, and drug development. Real-world examples of artificial intelligence technologies

implemented in clinical practice are discussed, along with the main challenges associated with their adoption.

Keywords: neural networks, medical diagnostics, artificial intelligence, machine learning, computer vision, diagnostic systems

Введение

Современный этап развития медицины характеризуется усиливающейся интеграцией цифровых технологий, среди которых искусственный интеллект занимает одно из центральных мест. Нейронные сети, являющиеся computational-моделями, архитектура которых инспирирована биологическими нейронными сетями мозга, демонстрируют значительный потенциал для трансформации подходов к медицинской диагностике. Диагностический процесс, по своей сути, представляет собой сложную задачу распознавания образов, сопряженную с необходимостью анализа многомерных и зашумленных данных, извлекаемых из анамнеза, лабораторных анализов и инструментальных исследований. На точность и скорость постановки диагноза влияют такие факторы, как утомление специалиста, когнитивные искажения, ограниченный опыт работы с редкими патологиями, а также постоянно растущий объем медицинской информации. Нейронные сети, обладающие способностью к выявлению сложных, неочевидных для человеческого восприятия паттернов в данных, позиционируются как инструмент поддержки принятия врачебных решений, способный повысить объективность, воспроизводимость и эффективность диагностики.

Принципы работы и архитектуры нейронных сетей, применимые в медицине

Нейронные сети относятся к классу алгоритмов машинного обучения с глубокой архитектурой (Deep Learning). Их фундаментальным строительным блоком является искусственный нейрон, который, получая на вход набор данных, производит над ними линейные и нелинейные преобразования с помощью функции активации. Соединяясь в слои, эти нейроны образуют сложные вычислительные графы, способные аппроксимировать чрезвычайно сложные зависимости между входными и выходными данными. Обучение сети заключается в итеративной настройке весовых коэффициентов связей между нейронами для минимизации ошибки предсказания на размеченном тренировочном наборе данных. Для задач медицинской диагностики наибольшее практическое применение нашли несколько архитектур. Сверточные нейронные сети (Convolutional Neural Networks, CNN) стали стандартом де-факто для анализа медицинских изображений. Их ключевое преимущество – способность автоматически извлекать иерархические пространственные признаки, начиная от простых граней и текстур и заканчивая сложными морфологическими структурами, такими как опухолевые образования или патологические изменения тканей. Рекуррентные нейронные сети (Recurrent Neural Networks, RNN), в частности их усовершенствованные варианты с долгой краткосрочной памятью (LSTM) и управляемыми рекуррентными блоками (GRU), эффективны для работы с последовательными

данными: временными рядами электроэнцефалограмм (ЭЭГ), электрокардиограмм (ЭКГ), динамическими показателями жизненно важных функций пациента. Гибридные и ансамблевые подходы, комбинирующие разные архитектуры, часто используются для интеграции мультимодальных данных, например, для совместного анализа изображений КТ и текстовых описаний из истории болезни.

Практическое применение в диагностической визуализации и онкологии

Область медицинской визуализации является лидером по внедрению нейросетевых технологий. В маммографии системы на основе CNN демонстрируют результаты, сопоставимые с квалификацией опытных радиологов. Исследование, проведенное международным консорциумом и опубликованное в журнале Nature, показало, что разработанная авторами нейросеть смогла снизить частоту ложноположительных диагнозов на 5,7% и ложноотрицательных на 9,4% в независимом тестовом наборе данных. В диагностике рака легких по данным низкодозовой компьютерной томографии (НДКТ) система, разработанная Google Health и Северо-Западным университетом, в ретроспективном исследовании продемонстрировала AUC (Area Under the Curve) 94,4%, превзойдя шестерых радиологов без доступа к предыдущим снимкам пациента. При этом алгоритм смог снизить количество ложноположительных результатов на 11% и ложноотрицательных на 5%. В гистопатологии, где анализ срезов тканей является «золотым стандартом» диагностики многих видов рака, нейросети автоматизируют процесс подсчета митозов, классификации типов опухолей и идентификации участков метастазирования. Платформа Ibex Medical Analytics использует алгоритмы искусственного интеллекта для анализа биопсий предстательной и молочной желез, показывая высокую точность в обнаружении злокачественных изменений, что подтверждено клиническими валидациями в медицинских центрах Европы и США.

Нейросети в кардиологии и неврологии

В кардиологии нейронные сети применяются для автоматизированного анализа электрокардиограмм. Исследователи из Стенфордского университета разработали алгоритм на основе глубокой сверточной сети, способный с высокой точностью выявлять бессимптомную дисфункцию левого желудочка по стандартной 12-канальной ЭКГ – состояние, которое ранее требовало для диагностики дорогостоящей эхокардиографии. Другое масштабное исследование, проведенное Mayo Clinic, продемонстрировало, что ИИ-модель может по сигналу ЭКГ с носимого устройства (например, Apple Watch) надежно обнаруживать фибрилляцию предсердий, открывая возможности для популяционного скрининга. В неврологии нейронные сети используются для ранней диагностики нейродегенеративных заболеваний. Алгоритмы, анализирующие МРТ-снимки головного мозга, научились идентифицировать паттерны, ассоциированные с болезнью Альцгеймера, за годы до появления выраженных клинических симптомов. Проект AI for Radiology от компании Siemens Healthineers включает инструменты, которые автоматически

сегментируют и измеряют объем гиппокампа – структуры, критически важной для памяти, атрофия которой является одним из ключевых маркеров болезни. Для диагностики инсульта по КТ-снимкам системы компьютерного зрения способны за несколько секунд детектировать зоны ишемии и кровоизлияния, что крайне важно для принятия решений о тромболитической терапии в условиях острого дефицита времени.

Вспомогательные и прогностические применения

Помимо прямой диагностики, нейронные сети находят применение в смежных областях, критически важных для здравоохранения. В фармацевтике генеративные нейросетевые модели используются для дизайна новых молекул-кандидатов в лекарственные препараты с заданными свойствами. Британская компания Exscientia с помощью своих платформ смогла сократить время доклинической разработки молекулы для лечения обсессивно-компульсивного расстройства с типичных 4-5 лет до примерно 12 месяцев. В эпидемиологическом прогнозировании модели, анализирующие данные поисковых запросов, активности в социальных сетях, мобильности населения и метеорологических условий, позволяют строить более точные прогнозы распространения инфекционных заболеваний, таких как грипп и COVID-19. Канадская платформа BlueDot, основанная на методах обработки естественного языка и машинного обучения, одной из первых в мире просигнализировала о вспышке неизвестного респираторного заболевания в Ухане в конце декабря 2019 года. Также в таблице приведены примеры областей применения, где нейросети показали отличный результат в изучении, прогнозировании (Таблица 1).

Таблица 1

Примеры клинически валидированных нейросетевых систем в диагностике

Область применения	Технология	Достигнутые результаты (по данным публикаций)
Офтальмология	Алгоритм диагностики диабетической ретинопатии (Google Health)	Чувствительность 87,2% и специфичность 90,7% при анализе изображений глазного дна, что соответствует уровню сертифицированных офтальмологов.
Дermатология	Система классификации кожных поражений (исследование Стэнфордского университета)	Точность дифференциальной диагностики меланомы и доброкачественных невусов, достигшая уровня дерматологов-экспертов в контролируемых условиях.
Пульмонология	Алгоритм для КТ легких (Lunit INSIGHT CXR, Южная Корея)	Получил разрешение регулирующих органов (CE Mark, FDA) для обнаружения пневмоторакса, узелков и других патологий с точностью, превышающей 97-98% для конкретных находок.

Вызовы и ограничения на пути клинической интеграции

Несмотря на впечатляющие успехи, интеграция нейронных сетей в рутинную клиническую практику сталкивается с системными барьерами. Проблема «черного ящика» остается одной из наиболее дискуссионных: сложность интерпретации решений, принимаемых глубокими нейросетями, подрывает доверие врачей и создает юридические риски. В ответ на это развивается направление Explainable AI (XAI), целью которого является создание методов визуализации и объяснения решений ИИ. Другой критический вызов – качество и презентабельность данных для обучения. Модели, обученные на данных из одного госпиталя или одной этнической группы, могут демонстрировать резкое падение точности при применении в других популяциях. Не менее остро стоят вопросы защиты конфиденциальности пациентов, необходимость проведения дорогостоящих рандомизированных клинических испытаний для доказательства эффективности и создание нормативно-правовой базы, регулирующей использование ИИ в медицине и распределение ответственности. В России разработкой стандартов в этой области занимается Росстандарт в рамках технического комитета «Искусственный интеллект».

Заключение

Нейронные сети прочно вошли в арсенал современных медицинских технологий, перейдя из стадии лабораторных экспериментов в фазу активного pilotирования и внедрения в клиниках по всему миру. Их способность к анализу сложных многомерных данных открывает новые возможности для повышения точности и скорости диагностики в радиологии, патологии, кардиологии и других специальностях. Доказано, что в ряде узких задач, таких как обнаружение специфических патологий на снимках, алгоритмы могут достигать и даже превосходить экспертный уровень. Однако трансформационный потенциал этих технологий реализуется не через замену врача, а через создание симбиотических систем «врач-ИИ», где интеллектуальный алгоритм выступает в роли высокоточного и неутомимого ассистента. Такой подход позволяет специалисту сконцентрироваться на сложных случаях, межличностном общении с пациентом и принятии итоговых клинических решений. Дальнейший прогресс будет зависеть не только от совершенствования самих алгоритмов, но и от решения комплексных проблем, лежащих в области регулирования, стандартизации и этики, а также от готовности медицинского сообщества к адаптации новых цифровых инструментов.

Библиографический список

1. Крыжановский, В. Д. Применение нейронной сети для решения задачи классификации в судебной медицине / В. Д. Крыжановский, Ю. А. Крыжановская // Вестник УрФО. Безопасность в информационной сфере. – 2023. – № 3(49). – С. 21-27. – DOI 10.14529/secur230302. – EDN RSVULP.
2. Мазуров, В. Д. Методы нейронных сетей и распознавания образов и их применение в экономике, технике и медицине / В. Д. Мазуров, А. И. Смирнов //

Инновации в современном мире: цели, приоритеты, решения : Материалы Международного научно-практического форума, Екатеринбург, 22–25 апреля 2014 года. Том Часть 2. – Екатеринбург: Уральский институт экономики, управления и права, 2014. – С. 187-201. – EDN TVCRPZ.

3. Ли, Г. Применение нейронных сетей в медицине: современные достижения и перспективы / Г. Ли // Новая наука: от идеи к результату. – 2025. – № 1. – С. 20-24. – EDN QSXCIK.

4. Габидулла, С. Г. Прогнозирование с использованием подбора весовых коэффициентов нейронной сети в медицине / С. Г. Габидулла // Студенческий вестник. – 2024. – № 45-13(331). – С. 10-12. – EDN KPXEFL.

5. Mannapova, R. A. Statistical analysis of the development of beekeeping in the categories of farms / R. A. Mannapova, L. I. Horuzhij, Z. A. Zalilova // European Journal of Natural History. – 2012. – No. 5. – P. 36. – EDN PWFNHR.

6. Уколова, А. В. Статистический и эконометрический анализ трудовых ресурсов регионов США по данным сельскохозяйственных переписей / А. В. Уколова, Б. Ш. Дашиева // Статистика в современном мире: методы, модели, инструменты : Материалы IV Международной научно-практической конференции, Ростов-на-Дону, 27 мая 2016 года. – Ростов-на-Дону: Ростовский государственный экономический университет "РИНХ", 2016. – С. 82-84. – EDN WQFYWZ.

7. Ukolova, A. V. Study of the Labor Resources of Peasant (Farm) Households by Production Type / A. V. Ukolova, B. S. Dashieva // Environmental Footprints and Eco-Design of Products and Processes. – 2022. – P. 229-241. – DOI 10.1007/978-981-16-8731-0_23. – EDN BELWLM.

8. Финансовое планирование, анализ и аудит финансовых показателей сельскохозяйственной организации / П. В. Антонов, С. В. Бодрикова, М. К. Джикия, О. О. Злобина // Профессия бухгалтера - важнейший инструмент эффективного управления сельскохозяйственным производством : Сборник научных трудов по материалам XI Международной научно-практической конференции, посвященной памяти профессора В.П. Петрова, Казань, 25–26 апреля 2023 года. – Казань: Казанский государственный аграрный университет, 2023. – С. 81-88. – EDN KAQMOS.

9. Харитонова, А. Е. Разработка модуля информационной системы распознавания образов / А. Е. Харитонова, А. Д. Титов // Цифровые технологии анализа данных в сельском хозяйстве. – Москва : «Научный консультант», 2022. – С. 211-241. – EDN CRKOMW.

УДК: 004.75:631.1

ERP-СИСТЕМЫ В УПРАВЛЕНИИ СЕЛЬСКИМ ХОЗЯЙСТВОМ

Гребёнкин Александр Михайлович, бакалавриат, институт Экономики и управления АПК, РГАУ-МСХА им. Тимирязева К. А., ag18032003@mail.ru

Никаноров Михаил Сергеевич, старший преподаватель кафедры прикладной информатики, ФГБОУ ВО РГАУ-МСХА им. К.А. Тимирязева, nikanorov@rgau-msha.ru

Научный руководитель: Степанцевич Марина Николаевна, к.э.н., доцент кафедры прикладной информатики, ФГБОУ ВО РГАУ-МСХА им. К.А. Тимирязева, stepancevich@rgau-msha.ru

Аннотация. В этой статье рассматривается вопрос о том, насколько эффективно применение ERP-систем в сфере управления сельским хозяйством. Авторы анализируют основные функции этих систем, такие как автоматизация учёта, прогнозирование урожайности, управление цепочками поставок, а также планирование и мониторинг ресурсов. Они отмечают, что внедрение ERP-технологий в сельское хозяйство способствует повышению эффективности управления, снижению затрат и улучшению качества принимаемых решений. В статье также приводятся примеры успешного использования ERP-систем в аграрной отрасли. На основе этих примеров выделяются ключевые факторы, способствующие успешной реализации этих технологий. Особое внимание уделяется тенденциям, связанным с переходом на современные информационные системы. В частности, отмечается необходимость масштабного обучения сотрудников и адаптации бизнес-процессов. В конце статьи обсуждаются перспективы использования ERP-систем в дальнейшем развитии сельского хозяйства. Подчёркивается их потенциал в условиях цифровизации агросектора.

Ключевые слова: ERP-системы, управление сельским хозяйством, автоматизация учёта, прогнозирование урожайности, эффективность управления.

ERP systems in agricultural management

Grebennik Alexander Mikhailovich, Bachelor's degree, Institute of Economics and Management of the Agroindustrial Complex, Russian State Agricultural Academy named after Timiryazeva K. A., ag18032003@mail.ru

Nikanorov Mikhail Sergeevich, Senior Lecturer at the Department of Applied Informatics, K.A. Timiryazev Russian State Pedagogical University, Moscow Agricultural Academy, nikanorov@rgau-msha.ru

Marina Nikolaevna Stepansevich, Candidate of Economics, Associate Professor of the Department of Applied Informatics, K.A. Timiryazev Russian State Pedagogical University, stepancevich@rgau-msha.ru

Annotation. This article examines the question of how effective the use of ERP systems in the field of agricultural management is. The authors analyze the main functions of these systems, such as accounting automation, yield forecasting, supply chain management, and resource planning and monitoring. They note that the

introduction of ERP technologies in agriculture helps to increase management efficiency, reduce costs and improve the quality of decisions. The article also provides examples of successful use of ERP systems in the agricultural sector. Based on these examples, the key factors contributing to the successful implementation of these technologies are highlighted. Special attention is paid to the trends related to the transition to modern information systems. In particular, the need for large-scale employee training and adaptation of business processes is noted. At the end of the article, the prospects of using ERP systems in the further development of agriculture are discussed. Their potential is emphasized in the context of digitalization of the agricultural sector.

Keywords: *ERP systems, agricultural management, accounting automation, yield forecasting, management efficiency.*

В последнее время в аграрной сфере происходят заметные перемены, вызванные активным использованием информационных технологий. Одним из ключевых инструментов в этой области являются ERP-системы, которые всё чаще применяются в сельском хозяйстве. В этой статье детально рассматривается, как внедрение ERP-систем может изменить подход к управлению в сельском хозяйстве.

ERP-системы – это комплексные платформы, которые объединяют в себе различные функции управления, такие как учёт, планирование, управление цепочками поставок и мониторинг ресурсов. Основная цель этих систем – автоматизировать рутинные процессы, что позволяет снизить влияние человеческого фактора и минимизировать вероятность ошибок в расчётах и учёте.

Отметим, что автоматизация учёта является одним из ключевых факторов успешного функционирования сельскохозяйственного предприятия. Точная информация о запасах, урожайности и финансах служит основой для принятия взвешенных управленческих решений. Одним из ключевых достоинств систем управления ресурсами предприятия (ERP) является их способность прогнозировать урожайность. С помощью современных технологий и алгоритмов эти системы могут анализировать данные за прошлые периоды и строить прогнозы на будущее. Они учитывают множество параметров, таких как погодные условия, характеристики выращиваемых культур и методы использования ресурсов. Это позволяет специалистам в области сельского хозяйства более точно планировать посевные работы и сбор урожая. В результате повышается эффективность работы предприятий и увеличивается прибыль.

Применение ERP-систем в сфере управления логистикой полностью трансформирует методы организации поставок. Это особенно актуально в условиях глобализации, когда конкуренция на рынке и снижение стоимости доставки становятся ключевыми факторами успеха компаний. Современные ERP-системы предоставляют эффективные инструменты для мониторинга перемещения товаров и оптимизации поставок. Они позволяют существенно

сократить издержки и оперативно реагировать на изменения рыночной конъюнктуры, что является фундаментом для успешной деятельности [1,2].

Хотя внедрение ERP-систем в сельскохозяйственную отрасль может быть успешным, оно сопряжено с определёнными трудностями. Важно обеспечить масштабное обучение персонала и адаптировать бизнес-процессы [4]. Традиционные методы работы глубоко укоренились, и их трансформация требует времени и ресурсов. Успех внедрения ERP-систем зависит не только от самой технологии, но и от готовности организации к изменениям. Это предполагает активное участие сотрудников на всех уровнях.

Опыт успешного применения ERP-систем в аграрном секторе наглядно демонстрирует, что при правильном внедрении этих решений можно достичь впечатляющих результатов. Некоторые компании, например, смогли значительно сократить время, необходимое для сбора и анализа информации, улучшить контроль над ресурсами и повысить качество принимаемых управлеченческих решений. Для эффективного внедрения этих технологий необходимо наличие квалифицированных специалистов, готовность к инновациям и активное участие всех заинтересованных сторон в процессе преобразований [3,5].

Применение систем управления ресурсами предприятия (ERP) в сельском хозяйстве открывает широкие горизонты, особенно в эпоху цифровизации аграрной отрасли. Эти системы предоставляют новые инструменты для сельскохозяйственных компаний, позволяя им адаптироваться к быстро меняющимся рыночным условиям и эффективно использовать большие объёмы данных для управления бизнес-процессами. В условиях быстрых климатических и экономических изменений успешное внедрение таких технологий становится ключевым фактором конкурентоспособности и стабильного роста сельскохозяйственных предприятий. Таким образом, внедрение ERP-систем в сельское хозяйство – это не просто технологический прорыв, а стратегический шаг к более эффективному и рациональному использованию ресурсов [6,7].

Библиографический список

1. Развитие цифровых компетенций специалистов агропромышленного комплекса на основе решений 1С / Е. В. Худякова, М. Н. Степанцевич, М. И. Горбачев, Т. Ф. Череватова // Актуальные вопросы социально-экономических, технических и естественных наук : Материалы Национальной (Всероссийской) научной конференции Института агроинженерии, Челябинск, 04–05 марта 2021 года. – Челябинск: Южно-Уральский государственный аграрный университет, 2021. – С. 93-98.
2. Худякова, Е. В. Кадровой потенциал АПК в условиях цифровой трансформации / Е. В. Худякова, М. И. Горбачев, М. Н. Кушнарева // Новые информационные технологии в образовании: Сборник научных трудов 20-й международной научно-практической конференции, Москва, 04–05 февраля 2020 года / Под общей редакцией Д.В. Чистова. Том Часть 1. – Москва:

Общество с ограниченной ответственностью "1С-Паблишинг", 2020. – С. 486-488.

3. Кушнарева, М. Н. Методические особенности определения эффективности внедрения информационных технологий на предприятии / М. Н. Кушнарева // Образование и наука без границ: фундаментальные и прикладные исследования. – 2016. – № 4. – С. 45-49.

4. Принципы управления научно-техническим развитием сельского хозяйства в призме риск-ориентированных подходов / В. Н. Кузьмин, Н. П. Мишурев, О. А. Моторин [и др.] // Управление рисками в АПК. – 2021. – № 3(41). – С. 9-15. – DOI 10.53988/24136573-2021-03-01.

5. Козубенко, И. С. Электронное сельское хозяйство: использование цифровых технологий для развития устойчивых инклюзивных продовольственных систем и интеграции торговли / И. С. Козубенко, О. А. Моторин, М. И. Горбачев // Управление рисками в АПК. – 2018. – № 3. – С. 126-138. – DOI 10.53988/24136573-2018-03-10.

6. Опыт системного подхода к цифровой трансформации АПК и направления реорганизации / В. И. Меденников, И. М. Кузнецов, М. В. Макеев, О. А. Моторин // Управление рисками в АПК. – 2020. – № 2(36). – С. 52-62. – DOI 10.53988/24136573-2020-02-07.

7. Худякова, Е. В. К вопросу о методике оценки экономической эффективности внедрения цифровых инноваций в сельское хозяйство / Е. В. Худякова, М. С. Никаноров, М. Н. Степанцевич // Экономика сельского хозяйства России. – 2023. – № 2. – С. 37-44.

8. Бухгалтерский финансовый учет в сельском хозяйстве : Под общей редакцией Н.Г. Белова, Л.И. Хоружий / Н. Г. Белов, Л. И. Хоружий, Н. Н. Карзаева [и др.]. Том 2. – Москва : Российский государственный аграрный университет - Московская сельскохозяйственная академия им. К.А. Тимирязева, 2010. – 363 с. – ISBN 978-5-9675-0372-6. – EDN SIOOUF.

9. Демичев, В. В. Анализ предпосылок формирования аграрных кластеров / В. В. Демичев // Экономика сельского хозяйства России. – 2012. – № 2. – С. 58-65. – EDN OWMAVZ.

10. Демичев, В. В. Кластеризация регионов России по уровню эффективности сельского хозяйства / В. В. Демичев, В. В. Маслакова, А. А. Нестратова // Бухучет в сельском хозяйстве. – 2020. – № 12. – С. 58-66. – DOI 10.33920/sel-11-2012-06. – EDN TKTBRZ.

11. Концевая, С. М. Учет биологических активов и финансовых результатов от их биотрансформации / С. М. Концевая, М. К. Джикия // Бухучет в сельском хозяйстве. – 2018. – № 8. – С. 39-47. – EDN VFAKIN.

12. Финансовое планирование, анализ и аудит финансовых показателей сельскохозяйственной организации / П. В. Антонов, С. В. Бодрикова, М. К. Джикия, О. О. Злобина // Профессия бухгалтера - важнейший инструмент эффективного управления сельскохозяйственным производством : Сборник

научных трудов по материалам XI Международной научно-практической конференции, посвященной памяти профессора В.П. Петрова, Казань, 25–26 апреля 2023 года. – Казань: Казанский государственный аграрный университет, 2023. – С. 81-88. – EDN KAQMSO.

13. Токарев, В. С. Социально-экологическая трансформация сельского хозяйства России / В. С. Токарев, В. В. Демичев // Московский экономический журнал. – 2023. – Т. 8, № 6. – DOI 10.55186/2413046X_2023_8_6_261. – EDN YDBFDL.

14. Маслакова, В. В. Статистический анализ эффективности инвестирования в развитие сельского хозяйства в России / В. В. Маслакова, В. В. Демичев. – Москва : Общество с ограниченной ответственностью "Научный консультант", 2021. – 194 с. – ISBN 978-5-907477-08-7. – EDN XZWHNF.

УДК: 004:631

АНАЛИЗ НАПРАВЛЕНИЙ ЦИФРОВИЗАЦИИ АГРОПРОМЫШЛЕННОГО КОМПЛЕКСА

Гребёнкин Александр Михайлович, бакалавриат, институт Экономики и управления АПК, РГАУ-МСХА им. Тимирязева К. А., ag18032003@mail.ru

Степанцевич Марина Николаевна, к.э.н., доцент кафедры прикладной информатики, ФГБОУ ВО РГАУ-МСХА им. К.А. Тимирязева, stepancevich@rgau-msha.ru

Научный руководитель: Никаноров Михаил Сергеевич, старший преподаватель кафедры прикладной информатики, ФГБОУ ВО РГАУ-МСХА им. К.А. Тимирязева, nikanorov@rgau-msha.ru

Аннотация. В данной статье проведён глубокий анализ современных технологий и решений для эффективного функционирования агропромышленного сектора. В исследовании рассматриваются различные направления цифровизации, которые помогают повысить качество управления сельским хозяйством, переработкой и распределением сельскохозяйственной продукции. Особое внимание уделяется интеграции данных, автоматизации процессов и использованию аналитических инструментов, которые позволяют принимать обоснованные управленческие решения. В статье также обсуждаются перспективы внедрения цифровых технологий в агропромышленном комплексе, рассматриваются вопросы кибербезопасности, а также их влияние на устойчивое развитие агросектора. В заключение подчёркивается важность применения цифровых решений для модернизации агропромышленного комплекса, что особенно актуально в условиях современного рынка.

Ключевые слова: Агропромышленный комплекс, информационные системы, инструменты, доступность технологий, инструментальные средства.

INFORMATION SYSTEM TOOLS IN THE AGRO-INDUSTRIAL COMPLEX

Grebennik Alexander Mikhailovich, Bachelor's degree, Institute of Economics and Management of the Agroindustrial Complex, Russian State Agricultural Academy named after Timiryazeva K. A., ag18032003@mail.ru

Marina Nikolaevna Stepancovich, Candidate of Economics, Associate Professor of the Department of Applied Informatics, K.A. Timiryazev Russian State Pedagogical University, stepancevich@rgau-msha.ru

Nikanorov Mikhail Sergeevich, Senior Lecturer at the Department of Applied Informatics, K.A. Timiryazev Russian State Pedagogical University, Moscow Agricultural Academy, nikanorov@rgau-msha.ru

Annotation. This article provides an in-depth analysis of modern technologies and solutions that are used in information systems for the effective functioning of the agro-industrial sector. The study examines various software and hardware tools that help to increase productivity in agricultural management, processing and distribution of agricultural products. Particular attention is paid to data integration, process automation, and the use of analytical tools that enable informed management decisions. The article also discusses current problems and prospects for the introduction of information technology in the agro-industrial complex. The issues of cybersecurity, accessibility of technologies for small and medium-sized enterprises, as well as their impact on the sustainable development of the agricultural sector are considered. In conclusion, the importance of tools as a factor contributing to modernization and innovation in the agro-industrial complex is emphasized. This is especially true in today's market conditions.

Keywords: Agro-industrial complex, information systems, tools, accessibility of technologies, tools.

Агропромышленный комплекс (АПК) – это ключевая сфера экономики, которая занимается производством и переработкой сельскохозяйственной продукции. В современном мире, где мы сталкиваемся с такими глобальными проблемами, как изменение климата, рост населения и необходимость обеспечения продовольственной безопасности, эффективное управление ресурсами становится всё более важным. Цифровые технологии играют ключевую роль в достижении этой цели, помогая интегрировать и оптимизировать процессы в АПК. Они позволяют эффективно использовать ресурсы, а также повышают эффективность и конкурентоспособность отрасли.

В современном сельском хозяйстве активно используются цифровые технологии, которые позволяют собирать, обрабатывать и анализировать данные, а также автоматизировать производственные и управлочные процессы. Одним из ключевых направлений в этой области являются системы управления ресурсами. Они помогают совершенствовать использование земельных, водных и энергетических ресурсов, что, в свою очередь, способствует повышению производительности и снижению затрат. Эти системы позволяют агробизнесу более эффективно планировать посевы, распределять ресурсы и управлять рисками, что в свою очередь, значительно повышает производительность и снижает расходы.

Среди множества полезных инструментов следует выделить геоинформационные системы (ГИС), которые предоставляют возможность отображать данные на карте и анализировать пространственные аспекты сельскохозяйственной деятельности. Благодаря ГИС специалисты в области сельского хозяйства могут отслеживать изменения в структуре почвы, обнаруживать участки, подверженные эрозии, эффективно планировать системы орошения и даже контролировать состояние урожая в режиме реального времени. Это позволяет принимать более обоснованные решения и повышать устойчивость к неблагоприятным внешним воздействиям [5,6].

В последнее время в агропромышленном комплексе активно внедряются технологии интернета вещей (IoT). Специальные датчики, установленные на полях, собирают информацию о влажности почвы, уровне освещённости и температуре. Эти данные отправляются в облачные хранилища, где их анализируют специальные программы. Благодаря этому фермеры могут в режиме реального времени отслеживать состояние посевов и оперативно реагировать на любые изменения [7]. Например, система может сигнализировать о необходимости полива или обработки растений. Это помогает снизить потери и повысить урожайность.

Ещё один важный аспект цифровизации АПК – использование больших данных (big data) и аналитики. Сбор и анализ огромного объёма информации о климатических условиях, потреблении ресурсов, урожайности и рыночных тенденциях позволяет делать более точные прогнозы и совершенствовать бизнес-процессы. Это открывает новые возможности для индивидуального подхода, когда решения принимаются на основе уникальных данных конкретного сельскохозяйственного предприятия. Такой подход, безусловно, способствует повышению эффективности работы в целом. Инструменты для анализа и моделирования, встроенные в информационные системы, значительно облегчают работу агрономов и менеджеров, позволяя им принимать более обоснованные решения [4]. Одним из таких инструментов являются прогнозные модели, которые на основе текущих данных и исторических показателей позволяют заранее оценить потенциальный урожай.

Это, в свою очередь, снижает финансовые риски и способствует более эффективному планированию сбора и реализации урожая.

В рамках интеграции цифровых решений в агропромышленный комплекс активно внедряются системы для автоматизации процессов. Эти решения охватывают различные аспекты, включая управление производственными потоками, логистику и финансовые операции. Внедрение специализированных программных решений не только повышает прозрачность и управляемость процессов, но и снижает количество ошибок и задержек, а также улучшает коммуникацию между всеми участниками в АПК [2].

В настоящее время в связи с активным внедрением цифровых технологий вопросы кибербезопасности становятся особенно важными. Необходимо обеспечивать надёжную защиту данных от несанкционированного доступа и гарантировать их целостность. Утечка или потеря информации могут привести к значительным экономическим потерям и снижению качества принимаемых решений.

Таким образом, использование современных цифровых технологий – это важный шаг на пути к обеспечению продовольственной безопасности и укреплению конкурентоспособности АПК. Инвестиции в цифровизацию АПК не только позволяют более эффективно управлять ресурсами, но и открывают новые возможности для создания инновационных продуктов и услуг, отвечающих современным требованиям.

В условиях быстро меняющегося мира эффективность АПК будет зависеть от способности её участников эффективно использовать потенциал информационных технологий для повышения производительности, устойчивости и качества продукции [3]. Это требует не только тщательного выбора инструментов, но и постоянного обучения и адаптации к новым вызовам. Только так можно обеспечить успешное развитие АПК в будущем.

Библиографический список

1. Худякова, Е. В. Кадровой потенциал АПК в условиях цифровой трансформации / Е. В. Худякова, М. И. Горбачев, М. Н. Кушнарева // Новые информационные технологии в образовании: Сборник научных трудов 20-й международной научно-практической конференции, Москва, 04–05 февраля 2020 года / Под общей редакцией Д.В. Чистова. Том Часть 1. – Москва: Общество с ограниченной ответственностью "1С-Паблишинг", 2020. – С. 486-488.
2. Худякова, Е. В. К вопросу о методике оценки экономической эффективности внедрения цифровых инноваций в сельское хозяйство / Е. В. Худякова, М. С. Никаноров, М. Н. Степанцевич // Экономика сельского хозяйства России. – 2023. – № 2. – С. 37-44.

3. Создание цифровых профилей сельскохозяйственных товаропроизводителей: Научное издание / О. А. Моторин, Н. П. Мишурев, В. И. Меденников [и др.]. – Москва: ФГБНУ «Росинформагротех», 2023. – 76 с.

4. Кушнарева, М. Н. Совершенствование информационного обеспечения стратегического планирования развития свеклосахарного подкомплекса региона / М. Н. Кушнарева, Ш. Е. Ванг // Международный научный журнал. – 2020. – № 3. – С. 28-35.

5. Моделирование бизнес-процессов на предприятиях АПК: Учебник для вузов / Е. В. Худякова, А. М. Бондаренко, Л. С. Качанова [и др.]. – 2-е издание, стереотипное. – Санкт-Петербург; Москва; Краснодар: Издательство "Лань", 2022. – 172 с. – (Высшее образование).

6. Искусственный интеллект в научно-техническом развитии сельского хозяйства / Н. П. Мишурев, В. Н. Кузьмин, О. А. Моторин [и др.] // Научно-информационное обеспечение инновационного развития АПК : Материалы XV Международной научно-практической конференции, р.п. Правдинский, Московская обл., 08 июня 2023 года. – Москва: Российский научно-исследовательский институт информации и технико-экономических исследований по инженерно-техническому обеспечению агропромышленного комплекса, 2023. – С. 78-83.

7. Технологии интернета вещей в кормопроизводстве и их эффективность / Е. В. Худякова, Х. К. Худякова, М. Н. Степанцевич [и др.] // Экономика сельскохозяйственных и перерабатывающих предприятий. – 2021. – № 3. – С. 31-38.

8. Хусаинова, А. С. Методические рекомендации по организации бухгалтерского учета в сельском хозяйстве в связи с принятием Федерального закона от 6 декабря 2011 г. № 402-ФЗ "О бухгалтерском учете" / А. С. Хусаинова, Н. Г. Белов, Л. И. Хоружий. – Москва : ФГБНУ «Росинформагротех», 2012. – 100 с. – EDN WPXRQL.

УДК 004.032.26:631.5

АВТОМАТИЗИРОВАННАЯ ИДЕНТИФИКАЦИЯ БОЛЕЗНЕЙ И ВРЕДИТЕЛЕЙ СЕЛЬСКОХОЗЯЙСТВЕННЫХ КУЛЬТУР ПО ФОТОГРАФИЯМ С ПОМОЩЬЮ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ НА PYTHON

Гридин Марсель Маратович, студент 4 курса факультета информационных систем и технологий, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, m.gridin@gk-osnova.ru

Арзуманян Аракат Арманович, студент 4 курса факультета информационных систем и технологии, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, melichev600@gmail.com

Научный руководитель – Уколова Анна Владимировна, к.т.н., доцент, доцент кафедры информационных систем, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, statmsha@rgau-msha.ru

Аннотация. В статье рассматривается применение сверточных нейронных сетей (CNN) для автоматической диагностики заболеваний сельскохозяйственных культур по изображениям листьев. Разработан прототип системы на языке Python с использованием библиотек TensorFlow и Keras. Модель на основе архитектуры EfficientNetB0 демонстрирует высокую точность классификации на публичном датасете PlantVillage. Результаты показывают перспективность использования данного подхода для создания мобильных решений в земледелии.

Ключевые слова: глубокое обучение, сверточные нейронные сети, компьютерное зрение, фитопатология, точное земледелие, Python, идентификация болезней растений.

AUTOMATED IDENTIFICATION OF CROP DISEASES AND PESTS FROM PHOTOS USING CONVOLUTIONAL NEURAL NETWORKS IN PYTHON

Marcel Maratovich Gridin, 4th-year student, Faculty of Information Systems and Technologies, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), m.gridin@gk-osnova.ru

Ararat Armanovich Arzumanyan, 4th-year student, Faculty of Information Systems and Technologies, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), melichev600@gmail.com

Scientific Supervisor: Anna Vladimirovna Utkova, Candidate of Technical Sciences, Associate Professor, Department of Information Systems, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), statmsha@rgau-msha.ru

Abstract. This paper explores the application of Convolutional Neural Networks (CNNs) for the automated diagnosis of crop diseases from leaf images. A prototype system was developed in Python using the TensorFlow and Keras libraries. The model, based on the EfficientNetB0 architecture, demonstrates high classification accuracy on the public PlantVillage dataset. The results highlight the potential of this approach for developing mobile agricultural solutions.

Keywords: deep learning, convolutional neural networks, computer vision, plant pathology, precision agriculture, Python, plant disease identification.

Введение. Современное сельское хозяйство сталкивается с необходимостью увеличения продуктивности в условиях ограниченности ресурсов и роста экологических требований. Одной из ключевых проблем являются потери урожая от болезней и вредителей, которые, по оценкам ФАО ООН, достигают 20-40% от мирового урожая ежегодно [1]. Традиционные методы диагностики основаны на визуальном осмотре растений специалистами-агрономами, что требует высокой квалификации и значительных временных затрат. В условиях крупных агрохолдингов оперативное реагирование на фитосанитарные угрозы становится критически важным.

Цифровизация агропромышленного комплекса открывает новые возможности для решения этих задач. Технологии компьютерного зрения на основе глубокого обучения, в частности сверточные нейронные сети (Convolutional Neural Networks, CNN), демонстрируют выдающиеся результаты в задачах классификации изображений [2]. Их применение для автоматической идентификации болезней растений позволяет создать эффективные инструменты массового мониторинга.

Целью данной работы являлась разработка и оценка эффективности программного прототипа на языке Python для автоматизированной идентификации болезней сельскохозяйственных культур по фотографиям листьев с использованием сверточных нейронных сетей. Для достижения цели были поставлены следующие задачи: анализ существующих решений и наборов данных; формирование и предобработка датасета для обучения; выбор и реализация архитектуры CNN; обучение модели и оценка ее метрик; разработка прототипа системы прогнозирования.

В качестве основного набора данных использовался публичный датасет PlantVillage [3], содержащий более 55 000 изображений листьев здоровых и инфицированных растений, снятых в лабораторных условиях на однородном фоне. Для исследования была выбрана культура томата как одна из наиболее значимых в овощеводстве. В экспериментах использовалось 5 классов: «здоровый томат», «томат с бактериальной пятнистостью», «томат с фитофторозом», «томат с мучнистой росой» и «томат с септориозом» (Рисунок 1). Выбор данных классов обусловлен их широкой распространностью и значительным экономическим ущербом, который они наносят.



здоровый лист б) бактериальная пятнистость) фитофто]



г) мучнистая роса



д) септориоз

Рисунок 1 – Примеры изображений из датасета PlantVillage: а) здоровый лист; б) бактериальная пятнистость; в) фитофтороз; г) мучнистая роса; д) септориоз

Для решения задачи классификации использовался подход трансферного обучения [4] с предобученной моделью EfficientNetB0. Данная архитектура была выбрана благодаря оптимальному соотношению точности и вычислительной эффективности, что особенно важно для потенциального внедрения в мобильные приложения или облачные сервисы с ограниченными ресурсами. Исходная модель была предобучена на наборе данных ImageNet. В рамках нашего исследования последний полно связанный слой был заменен на глобальный слой среднего пулинга (Global Average Pooling 2D) и новый классификатор, состоящий из двух полно связанных слоев с 128 и 5 нейронами соответственно. Для активации использовались функции ReLU (в скрытых слоях) и Softmax (в выходном слое).

Предобработка данных включала масштабирование пикселей до диапазона [0, 1] и изменение размера всех изображений до 224×224 пикселей. Для увеличения разнообразия данных и предотвращения переобучения применялась аугментация данных [5] в реальном времени во время обучения: случайные повороты на 20 градусов, горизонтальное и вертикальное отражение, случайное масштабирование до 20% и случайное изменение яркости.

Модель была реализована с использованием фреймворков TensorFlow 2.8 и Keras на языке Python 3.9. Обучение проводилось в течение 30 эпох с размером мини-батча 32. Для оптимизации использовался алгоритм Adam с начальной скоростью обучения 0.001. В качестве функции потерь применялась категориальная перекрестная энтропия. Для мониторинга процесса обучения использовался callback ReduceLROnPlateau, уменьшающий скорость обучения при отсутствии улучшения точности на валидационной выборке. Разделение данных составило 70% – обучение, 15% – валидация, 15% – тестирование.

В результате обучения была достигнута точность на тестовой выборке в 97,8%. Кривые обучения демонстрируют отсутствие переобучения: точность на тренировочной и валидационной выборках сходится, а потери стабильно уменьшаются. Для более детального анализа качества классификации была построена матрица ошибок (Таблица 1).

Таблица 1

Матрица ошибок классификации модели на тестовой выборке

Фактический / Прогноз	Здоровый	Бактериальная пятнистость	Фитофтороз	Мучнистая роса	Септориоз
Здоровый	248	0	2	0	0
Бактериальная пятнистость	1	231	0	3	0
Фитофтороз	3	0	245	2	0
Мучнистая роса	0	2	1	242	0
Септориоз	1	0	0	1	233

Анализ матрицы ошибок показывает, что модель надежно классифицирует все пять классов. Наибольшее количество ошибок (5) наблюдается между классами «Здоровый» и «Фитофтороз», что может быть объяснено схожестью начальных визуальных симптомов данных состояний. Также наблюдается незначительная путаница (3 ошибки) между «Бактериальной пятнистостью» и «Мучнистой росой».

Для практического использования модели был разработан прототип системы, блок-схема которого представлена на Рисунке 2. Система принимает входное изображение, выполняет его предобработку (изменение размера, нормализацию), передает в нейронную сеть и возвращает результат классификации с вероятностью принадлежности к каждому из классов.

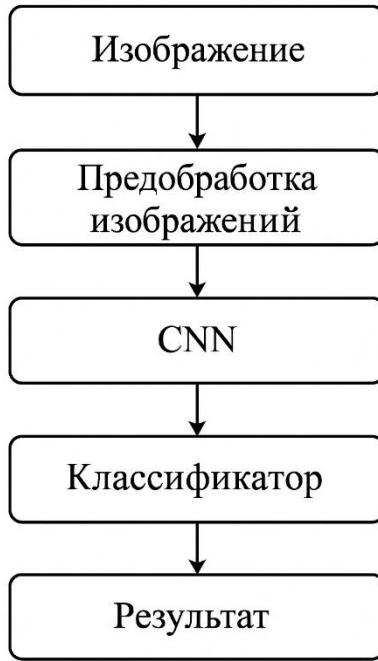


Рисунок 2 – Блок-схема работы системы прогнозирования

Рисунок 2 – Блок-схема работы системы прогнозирования

Основным ограничением исследования является использование датасета с изображениями, снятыми в лабораторных условиях на однородном фоне. В реальной полевой обстановке качество классификации может снизиться из-за сложного фона, изменчивого освещения, наличия капель воды, пыли и других артефактов.

В ходе работы был разработан программный прототип на Python для автоматизированной идентификации болезней томата по изображениям листьев. Применение подхода трансферного обучения с архитектурой EfficientNetB0 позволило достичь высокой точности классификации (97,8%) на тестовой выборке. Полученные результаты подтверждают перспективность использования сверточных нейронных сетей для задач фитопатологической диагностики в сельском хозяйстве.

Перспективы дальнейших исследований связаны с дообучением модели на данных, собранных в полевых условиях, расширением числа классифицируемых культур и заболеваний, а также интеграцией разработанного решения в мобильное приложение или облачную платформу для агрономов. Это позволит перейти от лабораторного прототипа к практическому инструменту, востребованному в условиях цифровой трансформации АПК.

Библиографический список

1. ФАО: Болезни сельскохозяйственных культур и их влияние на продовольственную безопасность. – М.: ФАО, 2020. – 68 с.

2. Гергель В.П., Стрижак В.В. Глубокое обучение в задачах компьютерного зрения. – М.: ДМК Пресс, 2021. – 564 с.
3. Hughes D., Salathé M. An open access repository of images on plant health to enable the development of mobile disease diagnostics – 2015.
4. Барский В.Б. Глубокие нейронные сети: методы и приложения. – СПб.: БХВ-Петербург, 2019. – 384 с.
5. Корнеев Г.В., Матвеев А.С. Аугментация данных в машинном обучении: методы и практическое применение // Программная инженерия. – 2022. – Т. 13, № 3. – С. 112-120.
6. Математическая статистика / О. Б. Таракова, Б. Ш. Дашиева, К. А. Козлов [и др.]. – Москвав : РГАУ-МСХА имени К.А. Тимирязева, Издательство «Научный консультант», 2025. – 130 с. – ISBN 978-5-907933-41-5. – EDN LPNIE.
7. Романцева, Ю. Н. Разработка мобильного приложения для сканирования молочной продукции / Ю. Н. Романцева, А. С. Невзоров // Цифровые технологии анализа данных в сельском хозяйстве. – Москва : «Научный консультант», 2022. – С. 128-178. – EDN PKQVSS.
8. Титов, А. Д. Анализ обеспеченности техникой сельского хозяйства Российской Федерации / А. Д. Титов // Сборник студенческих научных работ : по материалам докладов, 72-й Международной студенческой научно-практической конференции, посвященной 145-летию со дня рождения А.Г. Дояренко, Москва, 26–29 марта 2019 года. Том Выпуск 26. – Москва: Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2019. – С. 285-288. – EDN IXESMX.

УДК 004.85

ЭФФЕКТИВНОСТЬ ТРАНСФЕРНОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ НА ДАТАСЕТЕ CIFAR-10: СРАВНЕНИЕ ПОДХОДОВ И ВЛИЯНИЕ АРХИТЕКТУРЫ МОДЕЛИ.

Гринь Вероника Андреевна, студентка 2 курса бакалавриата института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, grinnika9@gmail.com

Научный руководитель: Храмов Дмитрий Эдуардович, старший преподаватель кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, khramovde@rgau-msha.ru

***Аннотация.** В статье исследуются подходы к обучению нейронных сетей на наборе данных CIFAR-10 с акцентом на сравнение эффективности двух методов: построение сверточной нейронной сети (CNN) с нуля и применение трансферного обучения на основе предобученной модели ResNet50V2. Проведён сравнительный анализ производительности обеих*

моделей, выявлены их сильные и слабые стороны, а также предложены рекомендации по оптимизации для задач классификации изображений.

Ключевые слова: сверточная нейронная сеть, трансферное обучение, предобученная модель, CIFAR-10, ResNet50V2

PERFORMANCE OF TRANSFER LEARNING FOR IMAGE CLASSIFICATION ON THE CIFAR-10 DATASET: COMPARISON OF APPROACHES AND IMPACT OF MODEL ARCHITECTURE.

Veronika Andreevna Grin, 2nd-year undergraduate student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), grinnika9@gmail.com

Scientific Supervisor: Dmitry Eduardovich Kramov, Senior Lecturer, Department of Statistics and Cybernetics, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), khramovde@rgau-msha.ru

Abstract. This article explores approaches to training neural networks on the CIFAR-10 dataset, focusing on comparing the performance of two methods: building a convolutional neural network (CNN) from scratch and applying transfer learning based on a pre-trained ResNet50V2 model. A comparative performance analysis of both models is conducted, identifying their strengths and weaknesses, and offering optimization recommendations for image classification tasks.

Key words: Convolutional neural network, transfer learning, pretrained architecture, CIFAR-10, ResNet50V2

Современные достижения в области машинного обучения открывают новые возможности для повышения эффективности нейронных сетей, особенно в условиях ограниченных вычислительных ресурсов и небольших объёмов данных. Одним из перспективных методов является трансферное обучение, которое позволяет использовать знания, накопленные моделью на крупномасштабных наборах данных, для решения специализированных задач с меньшими затратами [3].

В данной статье рассматривается классификация изображений на наборе данных CIFAR-10, который включает 60 000 цветных изображений размером 32×32 пикселя, разделённых на 10 классов (самолёт, автомобиль, птица, кошка, олень, собака, лягушка, лошадь, корабль, грузовик) [1]. Датасет, состоящий из 50 000 обучающих и 10 000 тестовых изображений, широко используется в исследованиях компьютерного зрения благодаря своей компактности и разнообразию.

Сверточные нейронные сети (CNN), впервые предложенные Яном Лекуном в 1988 году, являются основой для современных систем обработки изображений [2]. Их архитектура включает чередующиеся сверточные,

пулинговые и полносвязные слои, которые поэтапно извлекают признаки изображений – от простых текстур до сложных объектов. Эффективность CNN зависит от настройки гиперпараметров, таких как число слоёв, размер фильтров, функции активации и методы регуляризации, что определяет точность и устойчивость модели [2].

В рамках исследования были реализованы два подхода к классификации изображений CIFAR-10:

1. **Обучение CNN с нуля.** Разработана базовая сверточная нейронная сеть, включающая три сверточных блока с активацией ReLU, слоями MaxPooling и оптимизацией с помощью алгоритма Adam. После трёх эпох обучения модель достигла точности 61% на тестовом наборе, что значительно превосходит случайное угадывание (10%) и демонстрирует потенциал простых CNN для задач с ограниченными данными [1][2].

2. **Трансферное обучение с ResNet50V2.** В качестве второго подхода использовалась предобученная модель ResNet50V2, изначально обученная на наборе данных ImageNet с 1,2 миллиона изображений [3][4]. Для адаптации к CIFAR-10 модель была модифицирована: добавлены дополнительные слои и изменён выходной слой для соответствия 10 классам. Однако точность составила лишь 36,5%, что объясняется несколькими факторами: несоответствием размеров изображений (224×224 для ImageNet против 32×32 для CIFAR-10), ограниченным числом эпох (3) и отсутствием аугментации данных, что снизило способность модели к обобщению [3][4].

Полученные результаты подчёркивают, что трансферное обучение не всегда обеспечивает превосходство над моделями, обученными с нуля. Успех метода зависит от степени сходства между исходной и целевой задачами, включая размер изображений, количество классов и объём данных. Для датасета CIFAR-10 с его низким разрешением изображений предобученные модели, такие как ResNet50V2, требуют тщательной адаптации. Возможные улучшения включают:

- Разморозку части слоёв для тонкой настройки модели.
- Увеличение числа эпох обучения.
- Применение аугментации данных (например, повороты, сдвиги, изменения яркости).
- Использование более компактных архитектур, таких как EfficientNetB0, которые лучше подходят для небольших изображений [5].

Проведённые эксперименты показывают, что простая CNN, тщательно настроенная под задачу, может превзойти предобученную модель (61% против 36,5%), если последняя не адаптирована к специфике данных. Это подчёркивает важность осознанного выбора архитектуры и гиперпараметров в задачах компьютерного зрения. В дальнейшем рекомендуется исследовать гибридные подходы, сочетающие преимущества трансферного обучения и аугментации данных, для повышения точности и устойчивости моделей на компактных наборах данных, таких как CIFAR-10.

Библиографический список

1. Порохненко, Ю. С. Классификация изображений набора данных CIFAR-10 с помощью нейронных сетей / Ю. С. Порохненко, П. Н. Полежаев // Компьютерная интеграция производства и ИПИ-технологии : материалы VIII Всероссийской научно-практической конференции, Оренбург, 16–17 ноября 2017 года / Оренбургский государственный университет. – Оренбург: ОГУ, 2017. – С. 299–303. – EDN ZVTLXF.
2. Багаев, И. И. Анализ понятий нейронная сеть и свёрточная нейронная сеть, обучение свёрточной нейросети при помощи модуля TensorFlow / И. И. Багаев // Математическое и программное обеспечение систем в промышленной и социальной сферах. – 2020. – Т. 8, № 1. – С. 15–22. – DOI 10.18503/2306-2053-2020-8-1-15-22. – EDN IZBILN.
3. Pan, S. J., & Yang, Q. A Survey on Transfer Learning // IEEE Transactions on Knowledge and Data Engineering. – 2010. – Vol. 22, No. 10. – P. 1345–1359. – DOI 10.1109/TKDE.2009.191.
4. Hindarto, D. Use ResNet50V2 Deep Learning Model to Classify Five Animal Species / D. Hindarto // Jurnal JTIK (Jurnal Teknologi Informasi dan Komunikasi). – 2023. – Vol. 7, No. 4. – P. 758–768. – DOI 10.35870/jtik.v7i4.1845. – EDN ESHCPR.
5. Tan, M., & Le, Q. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks // Proceedings of the 36th International Conference on Machine Learning (ICML). – 2019. – P. 6105–6114.
6. Уколова, А. В. Эконометрика : практикум / А. В. Уколова, Е. В. Шайкина. – Москва : Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2011. – 105 с. – EDN WEDTMJ.
7. Зинченко, А. П. Региональная и муниципальная статистика : Практикум / А. П. Зинченко, В. В. Демичев. – Москва : Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2016. – 80 с. – EDN XRAUHH.
8. Козлов, К. А. Совершенствование системы статистических показателей растениеводства для выборочного наблюдения личных подсобных и других индивидуальных хозяйств граждан / К. А. Козлов // Экономика сельского хозяйства России. – 2023. – № 4. – С. 83-91. – DOI 10.32651/234-83. – EDN KOTKEW.
9. Уколова, А. В. Типология личных подсобных хозяйств по данным сельскохозяйственной микропереписи 2021 г / А. В. Уколова, К. А. Козлов // Экономика и управление: проблемы, решения. – 2024. – Т. 6, № 8(149). – С. 221-235. – DOI 10.36871/ek.up.p.r.2024.08.06.023. – EDN MNTLHJ.

БОЛЬШИЕ ЯЗЫКОВЫЕ МОДЕЛИ (LLM) ДЛЯ ИНТЕЛЛЕКТУАЛИЗАЦИИ ПРОИЗВОДСТВЕННЫХ ПРОЦЕССОВ В АПК

Громов Герман Дмитриевич, студента 2 курса института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева,
1434367@gmail.com

Научный руководитель – Бодур Айсу Мустафаевна, ассистент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К.А. Тимирязева,
bodur_a@rgau-msha.ru

Аннотация. В статье исследуется потенциал использования больших языковых моделей (LLM) как ключевого элемента технологической трансформации агропромышленного комплекса (АПК) России. Рассматриваются варианты, благодаря которым искусственный интеллект может изменить подходы к управлению, аналитике и стратегическому планированию в сельском хозяйстве.

Ключевые слова: большие языковые модели, искусственный интеллект, агропромышленный комплекс, цифровая трансформация, компьютерное зрение, точное земледелие, экономическая эффективность.

LARGE LANGUAGE MODELS (LLMs) FOR INTELLIGENT ENHANCEMENT OF AGRICULTURAL PRODUCTION PROCESSES

Gherman Dmitrievich Gromov, 2nd-year student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), 1434367@gmail.com

Scientific Supervisor: **Aysu Mustafaevna Bodur**, Assistant, Department of Statistics and Cybernetics, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), bodur_a@rgau-msha.ru

Abstract. This paper investigates the potential of Large Language Models (LLMs) as a key enabler of technological transformation in Russia's agro-industrial complex (AIC). It explores how artificial intelligence can reshape approaches to management, analytics, and strategic planning in agriculture.

Keywords: large language models, artificial intelligence, agro-industrial complex, digital transformation, computer vision, precision agriculture, economic efficiency.

Современный агропромышленный комплекс (АПК) России стоит на пороге технологического прорыва, обусловленного внедрением искусственного интеллекта. Одним из ключевых инструментов этой трансформации становятся большие языковые модели (LLM), способные кардинально изменить подходы к управлению, анализу и принятию решений в сельском хозяйстве.

Большая языковая модель (LLM) – это продвинутая система искусственного интеллекта, представляющая собой нейронную сеть, обученную на колоссальных объемах текстовой информации [1]. Главная способность LLM – понимать человеческий язык, обрабатывать текстовые запросы и генерировать новые, осмысленные тексты, которые практически неотличимы от написанных человеком. Проще говоря, это интеллектуальный ассистент, способный анализировать информацию и вести диалог на естественном языке [5].

Современные LLM основаны на архитектуре трансформеров (Transformers) с ключевым элементом в виде механизма внимания (attention). Этот механизм служит для определения смысловых связей между словами и выделения наиболее важных элементов контекста текста. Обучение модели строится на предсказании следующего элемента текста (токена) в последовательности. Такой метод позволяет модели с каждым шагом глубже понимать грамматические правила, сложные логические взаимосвязи и особенности предметной области. В результате LLM способны не только воспроизводить информацию, но и генерировать новые связные выводы, адаптированные под заданный контекст [2, 3].

Интеграция LLM в процессы АПК открывает значительные перспективы повышения эффективности и стабильности сельскохозяйственного производства. Рассмотрим ключевые направления их внедрения.

LLM как интеллектуальная система поддержки решений. Благодаря дообучению на специализированных агрономических данных, такие модели могут выполнять функцию виртуального эксперта-консультанта. Это дает возможность предоставлять рекомендации по выбору удобрений для конкретных типов почвы, оптимальным срокам сева и способам борьбы с вредителями, учитывая условия окружающей среды [1].

Синергия LLM с технологиями компьютерного зрения. Комплексное сочетание LLM и компьютерного зрения (CV) позволяет проводить детальную диагностику состояния сельскохозяйственных угодий [1]. Мониторинговое оборудование с технологиями CV – например, дроны или стационарные камеры – распознает признаки болезней растений, загрязнений почвы или недостатка питательных веществ [4]. Модель LLM интерпретирует анализ этих данных, преобразуя их в конкретные рекомендации для улучшения агротехнологических процессов. Например, при выявлении симптомов вируса картофеля модель может сформировать полный план необходимых действий наряду с подборкой актуальных научных исследований по данной проблеме.

Для демонстрации практической значимости больших языковых моделей (LLM) исследователями был рассмотрен гипотетический проект внедрения интеллектуальной системы в зерновое хозяйство площадью 500 гектаров. План технической реализации включает: Установку сети IoT-сенсоров для

мониторинга состояния почвы и воздуха; приобретение дронов, оснащенных мультиспектральными камерами; использование облачных сервисов для хранения данных и взаимодействия с LLM; дообучение базовой модели (Fine-tuning) на специализированных данных; разработку удобного пользовательского интерфейса и обучение сотрудников. Экономическая эффективность оценивается на основе предполагаемого роста урожайности на 10% и сокращения затрат на ресурсы. При средней урожайности 4 т/га и цене пшеницы 12 000 рублей за тонну, валовая выручка до внедрения системы составляет 24 миллиона рублей. После внедрения, с увеличением урожайности до 4,4 т/га, валовая выручка увеличивается до 26,4 миллиона рублей, что дает дополнительный доход в размере 2,4 миллиона рублей. Оптимизация расхода пестицидов и удобрений благодаря точному внесению позволяет сэкономить еще порядка 1 миллиона рублей. Итого, суммарная годовая выгода достигает примерно 3,4 миллиона рублей. С учетом первоначальных инвестиций порядка 5 миллионов рублей и годовых операционных затрат около 1 миллиона рублей, проект окупится за 1,5–2 года [1].

Таким образом, рассмотренный проект подтверждает высокий потенциал внедрения больших языковых моделей в производственный процесс организации АПК для повышения их эффективности и конкурентоспособности на рынке.

В ближайшие годы ожидается дальнейшая интеграция LLM в сельское хозяйство по следующим направлениям:

1. Автономные системы: Внедрение робототехники для создания полностью автономных комплексов выполнения полевых работ.
2. Гиперперсонализация: Разработка индивидуальных рекомендаций для ухода за каждым участком поля или отдельным растением.
3. Специализированные модели: Создание узкоспециализированных аграрных LLM, обученных исключительно на информации из области агрономии.
4. Международное сотрудничество: Формирование открытых глобальных баз знаний для обучения LLM с учетом международного опыта.
5. Генерация контента: Автоматическое обновление обучающих материалов и справочников для аграрных специалистов [1].

Для использования LLM в сельское хозяйство важно учитывать определенные критерии для получения максимальной выгоды. Территориальные и климатические условия России не позволяют создать единое решение, потому рекомендации больших языковых моделей должна формироваться с учетом климатических зон и размера сельскохозяйственного предприятия.

Так, для более южных регионов понадобиться анализ влажности почв и метеопрогнозов для оптимизации систем орошения и точного прогнозирования засушливых периодов, в то время как в Сибири предиктивные модели на базе LLM могут заранее предупреждать о рисках поздних заморозков, позволяя аграриям своевременно принять защитные меры и минимизировать потери урожая.

Что касается размера предприятий, крупные агрохолдинги располагают всеми необходимыми ресурсами и условиями для внедрения комплексных цифровых платформ. Большие объемы производства сильнее нуждаются в оптимизации высокопроизводительных вычислений для глубокого анализа производственной деятельности. Средним и малым хозяйствам будет целесообразней интегрировать LLM-технологии постепенно, для начала это могут быть облачные ИИ-сервисы, которые снизят затраты на оборудование и ИТ-инфраструктуру.

Большие языковые модели представляют собой не технологию будущего, а реальный инструмент цифровой трансформации сельского хозяйства в России. Их возможности в обработке и анализе больших объемов данных открывают новую эру интеллектуального земледелия, где накопленный человеческий опыт дополняется искусственным интеллектом. Для успешной реализации подобных инициатив важно учитывать региональные особенности и инвестировать в развитие цифровой инфраструктуры. В долгосрочной перспективе это поспособствует повышению производительности, укреплению конкурентоспособности отрасли и обеспечению продовольственной безопасности страны.

Библиографический список

1. Научный журнал «Agricultural Journal» [Электронный ресурс]. – URL: https://agvu.urgau.ru/images/Agricultural_Journal/2025/7-2025/12-7-2025.pdf (дата обращения: 14.05.2024).
2. Большие языковые модели [Электронный ресурс] // Википедия. – URL: <https://ru.wikipedia.org/wiki?curid=10130849> (дата обращения: 15.05.2024).
3. Большие языковые модели [Электронный ресурс] // SberDevices. – URL: <https://developers.sber.ru/help/gigachat-api/large-language-models> (дата обращения: 15.05.2024).
4. Практики применения искусственного интеллекта в сельском хозяйстве [Электронный ресурс]. – URL: <https://ict.moscow/analytics/praktiki-primenenii-iskusstvennogo-intellekta-v-selskom-khoziaistve/> (дата обращения: 15.05.2024).
5. Эффективные методы адаптации LLM к доменной специфике аграрного бизнеса [Электронный ресурс] // VetPress. – URL: <https://www.vetpress.ru/jour/article/view/3707> (дата обращения: 15.05.2024).
6. Бодур, А. М. Сельское хозяйство и изменение климата в рамках устойчивого развития / А. М. Бодур // Материалы II национальной научной конференции "Современные направления статистических исследований", Москва, 26 декабря 2023 года. – Москва: Российский государственный аграрный университет, 2024. – С. 14-22. – EDN JJVRJZ.
7. Цифровые технологии в сельском хозяйстве / В. И. Хоружий, А. В. Уkolova, В. В. Демичев [и др.]. – Москва : Российский государственный аграрный университет, 2024. – 234 с. – ISBN 978-5-9675-2056-3. – EDN FZBLXE.
8. Титов, А. Д. Методы и алгоритмы интеллектуального анализа больших данных в сельском хозяйстве / А. Д. Титов // Материалы международной

научно-практической конференции "Тренды развития сельского хозяйства и агрообразования в парадигме Зеленой экономики" : сборник статей, Москва, 14–15 июня 2023 года. – Москва: Российский государственный аграрный университет- Московская сельскохозяйственная академия им. К.А. Тимирязева, 2023. – С. 29-33. – EDN QZGBTG.

9. Горшкова, Д. А. Анализ системы показателей целей устойчивого развития / Д. А. Горшкова // Материалы II национальной научной конференции "Современные направления статистических исследований", Москва, 26 декабря 2023 года. – Москва: Российский государственный аграрный университет, 2024. – С. 122-130. – EDN APKNRM.

УДК: 004.8:004.942

ОБНАРУЖЕНИЕ ФЕЙКОВЫХ НОВОСТЕЙ

Зюбин Кирилл Александрович, студент 2 курса института экономики и управления АПК ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева.

Научный руководитель: Храмов Дмитрий Эдуардович, ассистент кафедры статистики и кибернетики института экономики и управления АПК ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, khramovde@rgau-msha.ru

Аннотация. В статье рассматривается проблема выявления фейковых новостей в Интернете и социальных сетях. Автор анализирует основные виды ложной информации и причины ее распространения, выделяя особенности кликбейта, пропаганды и некачественных публикаций. Особое внимание уделяется применению методов машинного обучения и обработки естественного языка (NLP) для автоматической классификации новостных сообщений. В статье описаны этапы создания модели на основе библиотеки TensorFlow, включая сбор и подготовку данных, токенизацию, векторизацию текста и построение рекуррентных нейронных сетей (RNN). Целью данной работы является разработка эффективной бинарной системы классификации, которая позволяет отличать реальные новости от поддельных с помощью современных инструментов искусственного интеллекта.

Ключевые слова: большие данные, искусственный интеллект, машинное обучение, обработка естественного языка, нейронные сети, TensorFlow, классификация текстов, фейковые новости.

DETECTING FAKE NEWS

Zyubin Kirill Aleksandrovich, 2st year student of the Institute of Economics and Management of Agroindustrial Complex of the Russian State Agrarian University – Moscow Timiryazev Agricultural Academy.

Scientific supervisor: Khramov Dmitry Eduardovich, assistant of the Department of Statistics and Cybernetics, Institute of Economics and Management of Agroindustrial Complex of the Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, khramovde@rgau-msha.ru

Annotation. *The article discusses the problem of identifying fake news on the Internet and social media. The author analyzes the main types of false information and the reasons for its spread, highlighting the features of clickbait, propaganda, and low-quality publications. Special attention is paid to the application of machine learning and natural language processing (NLP) methods for automatic classification of news messages. The article describes the steps of creating a model based on the TensorFlow library, including data collection and preparation, tokenization, text vectorization, and the construction of recurrent neural networks (RNNs). The goal of this work is to develop an effective binary classification system that allows us to distinguish between real and fake news using modern artificial intelligence tools.*

Key words: Big Data, Artificial Intelligence, Machine learning, Natural language processing, Neural networks, TensorFlow, Text classification, Fake news.

Фейковые новости окружают нас повсюду и в нынешних реалиях способность различать фейк от правды крайне актуальна. Человеку данная задача практически неподсильна ведь мы не можем обрабатывать тысячи закономерностей которые в последствии приведут нас к выводу данная информация фейк или истина однако это посильно искусенному интеллекту.

«Все они манипулируют эмоциями людей. Именно поэтому модели обработки естественного языка (NLP) и машинного обучения могут выявлять закономерности в них»[1].

Актуальность темы обусловлена стремительным развитием цифровых технологий и ростом объёмов информации, распространяемой через интернет и социальные сети. В современных условиях пользователи всё чаще сталкиваются с явлением фейковых новостей намеренноискажённых или ложных сообщений, создаваемых с целью манипулирования общественным мнением, политического или экономического воздействия, а также для увеличения популярности определённых интернет-ресурсов. Проблема достоверности информации становится особенно важной, поскольку фейковые новости распространяются быстрее правдивых, оказывая существенное влияние на формирование общественного сознания. В связи с этим возникает необходимость разработки автоматизированных систем, способных выявлять ложные материалы на основе анализа текстового контента.

Для эффективного противодействия распространению ложных данных требуется автоматизированная система, способная отличать правдивые новости от фейковых. Поскольку целью является именно разделение информации на две категории – «достоверная» и «ложная», задача сводится к бинарной классификации текстов. Такое разделение является базовым элементом при обучении искусственного интеллекта, что делает возможным применение методов машинного обучения и обработки естественного языка (NLP). “Эмоция

в современных СМИ становится важнее факта, а мнение – важнее достоверности. Изучение отклонения от истины является предметом лингвистического исследования ...”[2].

Построение модели обнаружения фейковых новостей с использованием библиотеки TensorFlow представляет собой поэтапный процесс, включающий сбор и подготовку данных, их векторизацию, построение архитектуры нейронной сети, обучение и последующую оценку точности модели. TensorFlow, созданный компанией Google, является одной из наиболее мощных и гибких платформ для реализации алгоритмов глубокого обучения. Он предоставляет обширный набор инструментов для работы с текстами, что делает его оптимальным выбором для задач обработки естественного языка и классификации новостных сообщений.

“В общем виде распознавание эмоциональной окраски текста состоит из следующих этапов: предобработка исходных данных, извлечение признаков (векторизация), построение классификаторов машинного обучения и оценка качества классификаторов”[4].

Первым этапом при создании системы выявления фейков является сбор и подготовка данных. Для обучения модели требуется репрезентативный набор новостных текстов, содержащий как достоверные, так и ложные статьи. Такие датасеты могут формироваться на основе открытых источников, специализированных хранилищ данных или собираться вручную с последующей разметкой. Важно, чтобы в обучающей выборке присутствовали тексты различной тематики – политической, экономической, социальной и развлекательной направленности, поскольку это повышает универсальность модели. На этапе предобработки проводится очистка текстов: удаляются HTML-теги, пунктуация, цифры, эмодзи, а также стоп-слова, не несущие смысловой нагрузки. При необходимости выполняется лемматизация или стемминг, то есть приведение слов к их базовой форме. Такая нормализация обеспечивает унификацию данных и позволяет сократить размер словаря, что ускоряет процесс обучения.

После очистки данных выполняется токенизация – разбиение текста на отдельные слова или последовательности символов. Поскольку нейронные сети оперируют исключительно числовыми значениями, следующим шагом является преобразование слов в векторное представление. Для этого применяются методы векторизации, наиболее известным из которых является Word2Vec. Данный подход позволяет отображать слова в многомерное пространство, где близкие по смыслу термины располагаются на небольшом расстоянии друг от друга. Таким образом, модель получает возможность улавливать семантические взаимосвязи между словами и контекстом предложения. В TensorFlow этот этап можно реализовать с помощью встроенного слоя Embedding, который обучается совместно с моделью и формирует оптимальные векторные представления слов на основе контекста.

Следующий этап – построение архитектуры нейронной сети. Для задачи бинарной классификации новостей часто используется комбинация рекуррентных и сверточных слоёв, позволяющая одновременно учитывать

контекст и локальные признаки текста. На практике архитектура может иметь следующую структуру: слой Embedding, который преобразует токены в векторы; слой Dropout, предотвращающий переобучение за счёт случайного обнуления части нейронов; слой LSTM, отвечающий за обработку последовательной информации и запоминание контекста; слой Dense с функцией активации ReLU, выполняющий свёртку полученных признаков, и завершающий слой с сигмоидальной активацией, возвращающий вероятность того, что анализируемая новость является фейковой. Подобная архитектура отличается простотой реализации, устойчивостью к переобучению и высокой точностью при достаточном объёме данных.

На этапе обучения модели в TensorFlow определяется функция потерь (обычно binary crossentropy для бинарной классификации), а также оптимизатор, который управляет процессом корректировки весов нейронной сети. Наиболее распространёнными являются Adam и RMSprop, обеспечивающие быстрое и стабильное сходимое обучение. В процессе тренировки модель многократно проходит через обучающую выборку, минимизируя ошибку предсказания. После каждого эпоха обучения производится проверка на валидационной выборке, что позволяет контролировать динамику обучения и предотвращать переобучение. Для повышения устойчивости к шумам и редким словам в тексте часто применяется регуляризация и ограничение длины входных последовательностей.

После завершения обучения производится оценка эффективности модели. Основными метриками в данном случае являются точность (accuracy), полнота (recall), точность классификации по классам (precision) и F1-мера, которая отражает баланс между ними. В зависимости от характера данных возможно использование дополнительных метрик, таких как ROC-AUC, демонстрирующей способность модели различать положительные и отрицательные классы. На основе полученных результатов можно корректировать архитектуру сети, изменять параметры обучения или объём данных, добиваясь оптимального соотношения между скоростью и точностью.

Важно отметить, что практическая ценность модели определяется не только уровнем её точности, но и способностью адаптироваться к новым типам фейковых сообщений. Для этого применяются методы дообучения (fine-tuning) на новых данных, поступающих после первоначального обучения. TensorFlow позволяет реализовать подобную гибкость за счёт сохранения и дообучения весов модели без необходимости её полного переобучения. Кроме того, возможно использование предобученных языковых моделей, таких как BERT или DistilBERT, интегрируемых в TensorFlow. Они позволяют значительно повысить качество классификации, особенно при работе с малым объёмом данных.

Таким образом, построение модели обнаружения фейковых новостей на основе TensorFlow представляет собой комплексный процесс, включающий в себя тщательную подготовку данных, выбор подходящей архитектуры нейронной сети и оптимизацию параметров обучения. Применение данной платформы обеспечивает не только высокую точность определения ложных

сообщений, но и возможность масштабирования системы, что делает её пригодной для анализа больших потоков информации в реальном времени. Использование TensorFlow в сочетании с современными методами обработки естественного языка позволяет создавать интеллектуальные решения, способные эффективно выявлять и ограничивать распространение недостоверной информации в медиапространстве.

Построение модели обнаружения фейковых новостей с использованием библиотеки TensorFlow представляет собой поэтапный процесс, включающий сбор и подготовку данных, их векторизацию, построение архитектуры нейронной сети, обучение и последующую оценку точности модели. TensorFlow, созданный компанией Google, является одной из наиболее мощных и гибких платформ для реализации алгоритмов глубокого обучения. Он предоставляет обширный набор инструментов для работы с текстами, что делает его оптимальным выбором для задач обработки естественного языка и классификации новостных сообщений.

Первым этапом при создании системы выявления фейков является сбор и подготовка данных. Для обучения модели требуется репрезентативный набор новостных текстов, содержащий как достоверные, так и ложные статьи. Такие датасеты могут формироваться на основе открытых источников, специализированных хранилищ данных или собираться вручную с последующей разметкой. Важно, чтобы в обучающей выборке присутствовали тексты различной тематики – политической, экономической, социальной и развлекательной направленности, поскольку это повышает универсальность модели. На этапе предобработки проводится очистка текстов: удаляются HTML-теги, пунктуация, цифры, эмодзи, а также стоп-слова. “Стоп-словами являются те слова, которые не несут смысловой нагрузки, например, предлоги и артикли”[3]. При необходимости выполняется лемматизация или стемминг. “Стемминг – усечение слов до их основы посредством отбрасывания предлогов и суффиксов”[3]. Такая нормализация обеспечивает унификацию данных и позволяет сократить размер словаря, что ускоряет процесс обучения.

После очистки данных выполняется токенизация – разбиение текста на отдельные слова или последовательности символов. Поскольку нейронные сети оперируют исключительно числовыми значениями, следующим шагом является преобразование слов в векторное представление. Для этого применяются методы векторизации, наиболее известным из которых является Word2Vec. Данный подход позволяет отображать слова в многомерное пространство, где близкие по смыслу термины располагаются на небольшом расстоянии друг от друга. Таким образом, модель получает возможность улавливать семантические взаимосвязи между словами и контекстом предложения. В TensorFlow этот этап можно реализовать с помощью встроенного слоя Embedding, который обучается совместно с моделью и формирует оптимальные векторные представления слов на основе контекста.

Следующий этап – построение архитектуры нейронной сети. Для задачи бинарной классификации новостей часто используется комбинация рекуррентных и сверточных слоёв, позволяющая одновременно учитывать

контекст и локальные признаки текста. На практике архитектура может иметь следующую структуру: слой Embedding, который преобразует токены в векторы; слой Dropout, предотвращающий переобучение за счёт случайного обнуления части нейронов; слой LSTM, отвечающий за обработку последовательной информации и запоминание контекста; слой Dense с функцией активации ReLU, выполняющий свёртку полученных признаков, и завершающий слой с сигмоидальной активацией, возвращающий вероятность того, что анализируемая новость является фейковой. Подобная архитектура отличается простотой реализации, устойчивостью к переобучению и высокой точностью при достаточном объёме данных.

На этапе обучения модели в TensorFlow определяется функция потерь (обычно binary crossentropy для бинарной классификации), а также оптимизатор, который управляет процессом корректировки весов нейронной сети. Наиболее распространёнными являются Adam и RMSprop, обеспечивающие быстрое и стабильное сходимое обучение. В процессе тренировки модель многократно проходит через обучающую выборку, минимизируя ошибку предсказания. После каждого эпоха обучения производится проверка на валидационной выборке, что позволяет контролировать динамику обучения и предотвращать переобучение. Для повышения устойчивости к шумам и редким словам в тексте часто применяется регуляризация и ограничение длины входных последовательностей.

После завершения обучения производится оценка эффективности модели. Основными метриками в данном случае являются точность (accuracy), полнота (recall), точность классификации по классам (precision) и F1-мера, которая отражает баланс между ними. В зависимости от характера данных возможно использование дополнительных метрик, таких как ROC-AUC, демонстрирующей способность модели различать положительные и отрицательные классы. На основе полученных результатов можно корректировать архитектуру сети, изменять параметры обучения или объём данных, добиваясь оптимального соотношения между скоростью и точностью.

Важно отметить, что практическая ценность модели определяется не только уровнем её точности, но и способностью адаптироваться к новым типам фейковых сообщений. Для этого применяются методы дообучения (fine-tuning) на новых данных, поступающих после первоначального обучения. TensorFlow позволяет реализовать подобную гибкость за счёт сохранения и дообучения весов модели без необходимости её полного переобучения. Кроме того, возможно использование предобученных языковых моделей, таких как BERT или DistilBERT, интегрируемых в TensorFlow. Они позволяют значительно повысить качество классификации, особенно при работе с малым объёмом данных.

Таким образом, построение модели обнаружения фейковых новостей на основе TensorFlow представляет собой комплексный процесс, включающий в себя тщательную подготовку данных, выбор подходящей архитектуры нейронной сети и оптимизацию параметров обучения. Применение данной платформы обеспечивает не только высокую точность определения ложных

сообщений, но и возможность масштабирования системы, что делает её пригодной для анализа больших потоков информации в реальном времени. Использование TensorFlow в сочетании с современными методами обработки естественного языка позволяет создавать интеллектуальные решения, способные эффективно выявлять и ограничивать распространение недостоверной информации в медиапространстве.

Таким образом, в ходе рассмотрения проблемы обнаружения фейковых новостей было установлено, что данное направление является одним из наиболее актуальных в современной информационной среде. В условиях постоянного увеличения объёма новостного контента и высокой скорости его распространения традиционные методы проверки достоверности теряют эффективность, уступая место интеллектуальным системам, основанным на машинном обучении и обработке естественного языка.

Анализ существующих подходов показал, что применение алгоритмов глубокого обучения, в частности нейронных сетей, открывает широкие возможности для автоматического распознавания ложных материалов. Рекуррентные, сверточные и гибридные архитектуры демонстрируют высокую способность к выявлению скрытых манипулятивных признаков в тексте, а использование трансформерных моделей позволяет учитывать сложные семантические связи и контекстные зависимости между словами.

Особое значение имеет применение платформы TensorFlow, обеспечивающей гибкость и масштабируемость при построении моделей машинного обучения. Благодаря широкому набору инструментов и поддержке современных архитектур, TensorFlow позволяет создавать эффективные решения, способные анализировать большие массивы данных в реальном времени. Разработанная на его основе система классификации новостей может не только определять достоверность информации, но и адаптироваться к новым форматам фейков, что особенно важно в условиях быстро меняющегося медиапространства.

Использование методов машинного обучения в сфере информационной безопасности способствует формированию более прозрачного и устойчивого цифрового общества. Автоматизация процесса проверки достоверности новостных материалов позволяет сократить влияние дезинформации на общественное мнение, повысить уровень медиаграмотности населения и обеспечить более ответственное потребление информационных ресурсов.

В перспективе развитие подобных систем может быть направлено на интеграцию алгоритмов объяснимого искусственного интеллекта, что позволит не только классифицировать тексты, но и обосновывать принятые решения. Это повысит доверие пользователей к автоматизированным системам и создаст предпосылки для их широкого внедрения в журналистику, государственные структуры и социальные платформы.

Итак, использование технологий машинного обучения для выявления фейковых новостей представляет собой важный шаг в развитии инструментов цифровой аналитики и защиты информационного пространства. Такие подходы обеспечивают не только повышение точности анализа, но и укрепление

принципов достоверности, прозрачности и ответственности в современном медиапространстве.

Библиографический список

1. *Перевод статьи Nithiwat Sir: Detecting Thai Fake News with Machine Learning*
2. Николаева Анастасия Владимировна Языковые особенности фейковых публикаций // Верхневолжский филологический вестник. 2019. №3. URL: <https://cyberleninka.ru/article/n/yazykovye-osobennosti-feykovyh-publikatsiy> (дата обращения: 26.10.2025).
3. Хотин Д. Ю., Иванова Г. С. ВЫЯВЛЕНИЕ ФЕЙКОВЫХ ФРАГМЕНТОВ В ТЕКСТОВЫХ НОВОСТНЫХ СООБЩЕНИЯХ С ПОМОЩЬЮ МАШИННОГО ОБУЧЕНИЯ // Вестник науки. 2024. №6 (75). URL: <https://cyberleninka.ru/article/n/vyyavlenie-feykovyh-fragmentov-v-tekstovuyh-novostnyh-soobscheniyah-s-pomoschyu-mashinnogo-obucheniya>
4. Анастасия Александровна Двойникова, Кристина Олеговна Кондратенко ПОДХОД К АВТОМАТИЧЕСКОМУ РАСПОЗНАВАНИЮ ЭМОЦИЙ В ТРАНСКРИПЦИЯХ РЕЧИ // Приборостроение. 2023. №10. URL: <https://cyberleninka.ru/article/n/podhod-k-avtomaticheskому-raspoznavaniyu-emotsiy-v-transkriptsiyah-rechi>
5. Ukolova, A. V. Study of the Labor Resources of Peasant (Farm) Households by Production Type / A. V. Ukolova, B. S. Dashieva // Environmental Footprints and Eco-Design of Products and Processes. – 2022. – P. 229-241. – DOI 10.1007/978-981-16-8731-0_23. – EDN BELWLM.
6. Храмов, Д. Э. Онтология алгоритмов оценки продолжительности жизненного цикла программного обеспечения / Д. Э. Храмов // Проблемы управления в социально-экономических и технических системах : Материалы XX Международной научно-практической конференции. Сборник научных статей, Саратов, 17–18 апреля 2024 года. – Саратов: Издательский центр "Наука", 2024. – С. 137-140. – EDN RQHOFT.
7. Романова, М. А. Алгоритмы обработки текста / М. А. Романова, Д. Э. Храмов // Материалы международной научно-практической конференции "Тренды развития сельского хозяйства и агрообразования в парадигме Зеленой экономики" : сборник статей, Москва, 14–15 июня 2023 года. – Москва: Российский государственный аграрный университет- Московская сельскохозяйственная академия им. К.А. Тимирязева, 2023. – С. 252-257. – EDN HZDKZR.

АВТОМАТИЧЕСКАЯ ДИАГНОСТИКА ЗАБОЛЕВАНИЙ РАСТЕНИЙ: ЭВОЛЮЦИЯ ОТ КЛАССИФИКАЦИИ К ДЕТЕКЦИИ

Казлаускас Анастасия Сергеевна, студентка 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, kazlauskas24@mail.ru

Мерзлякова Мария Андреевна, студентка 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, vifif04v@mail.ru

Научный руководитель – Храмов Дмитрий Эдуардович, старший преподаватель кафедры статистики и кибернетики, ФГБОУ ВО РГАУ-МСХА имени К. А. Тимирязева, khramovde@rgau-msha.ru

Аннотация. В статье рассматривается развитие подходов к автоматической диагностике болезней растений – от традиционных методов классификации изображений до современных систем детекции на основе глубоких нейронных сетей. Описаны преимущества и ограничения существующих решений, а также обозначены перспективные направления исследований, включая мультимодальный анализ данных, методы маловыборочного обучения и интеграцию с беспилотными системами. Подчеркивается роль таких технологий в обеспечении эффективности и устойчивости агропромышленного производства.

Ключевые слова: болезни растений, автоматическая диагностика, компьютерное зрение, машинное обучение, глубокие нейронные сети, классификация, детекция, сельское хозяйство, мониторинг посевов.

Введение

Болезни растений остаются одной из ключевых причин снижения урожайности во всем мире, приводя к утрате значительной части сельскохозяйственной продукции. Традиционные методы диагностики, основанные на визуальной оценке специалистами, обеспечивают высокую точность, но требуют существенных временных и материальных затрат. В условиях растущего спроса на продовольствие особое значение приобретают технологии, способные автоматизировать процесс распознавания заболеваний. Современные методы машинного обучения и компьютерного зрения позволяют проводить быструю и точную оценку состояния растений, выявляя патологии на ранних этапах развития. Эволюция таких технологий демонстрирует переход от простых алгоритмов классификации изображений к комплексным нейросетевым системам, обеспечивающим детекцию и локализацию пораженных участков. Анализ этого процесса позволяет определить текущее состояние отрасли и направления её дальнейшего развития.

Этап классификации заболеваний

Первые разработки в области автоматического распознавания заболеваний растений ориентировались на задачу классификации изображений, то есть определение принадлежности растения к категории «здоровое» или «поражённое». Основу таких систем составляли классические алгоритмы машинного обучения, включая метод опорных векторов и случайные леса. Эффективность этих подходов зависела от ручного извлечения признаков – цветовых характеристик, текстурных дескрипторов и геометрических параметров поражений. Несмотря на простоту реализации и невысокие требования к вычислительным ресурсам, подобные методы обладали ограниченной обобщающей способностью и слабо адаптировались к изменению условий съёмки. Существенный прогресс был достигнут с внедрением глубокого обучения. Сверточные нейронные сети, такие как AlexNet, VGG и ResNet, позволили автоматически извлекать информативные признаки из изображений без предварительной обработки [1]. Появление крупных открытых наборов данных, например PlantVillage, ускорило развитие данного направления и способствовало повышению точности классификации [2].

Переход к методам детекции

Простая классификация изображений оказалась недостаточной для применения в реальных условиях, где на одном снимке могут присутствовать несколько растений или различные типы поражений. Это обусловило переход к методам детекции, сочетающим классификацию и пространственную локализацию областей с признаками болезни. Современные решения используют двухэтапные архитектуры, такие как Faster R-CNN, и одноэтапные модели, включая YOLO и SSD [3]. В последние годы активно развиваются детекторы нового поколения на основе трансформеров, например DETR, которые обеспечивают высокую точность без необходимости ручной настройки параметров. Эти технологии позволяют выявлять несколько заболеваний одновременно и применять системы анализа не только для лабораторных изображений, но и для полевых снимков, полученных с беспилотных летательных аппаратов.

Преимущества и ограничения

Автоматизированные системы диагностики обладают рядом очевидных преимуществ. Они обеспечивают высокую скорость анализа, способны обрабатывать большие объёмы данных, снижая зависимость от человеческого фактора, и демонстрируют точность, сопоставимую с экспертной оценкой. Внедрение таких решений способствует сокращению затрат на агромониторинг и повышает оперативность принятия управлеченческих решений. Однако широкому применению мешают определённые ограничения. К ним относятся зависимость от условий съёмки, необходимость адаптации алгоритмов к специфике конкретных культур и регионов, высокая стоимость оборудования и вычислительных мощностей, а также нестабильность работы при анализе изображений низкого качества, полученных в неконтролируемых полевых условиях.

Перспективы развития

Современные исследования направлены на повышение устойчивости и универсальности систем автоматической диагностики [4]. Особое внимание уделяется применению мультимодальных данных, объединяющих визуальную, гиперспектральную и тепловизионную информацию, что позволяет повысить точность распознавания при изменении внешних факторов. Перспективным направлением является маловыборочное обучение, позволяющее моделям эффективно распознавать редкие заболевания при ограниченном объёме обучающих примеров. Важное значение приобретает интеграция диагностических модулей с беспилотными летательными аппаратами и системами Интернета вещей, обеспечивающими сбор и анализ информации о состоянии посевов в режиме реального времени. Особый интерес вызывает развитие методов интерпретируемости моделей, направленных на объяснение логики их решений. Прозрачность алгоритмов способствует росту доверия со стороны агрономов и упрощает практическое внедрение интеллектуальных технологий в производство.

Заключение

Развитие систем автоматической диагностики болезней растений демонстрирует поступательную эволюцию от классических методов классификации изображений к современным нейросетевым архитектурам, способным выполнять точную детекцию поражений. Эти технологии доказали свою эффективность и становятся важным инструментом в цифровой трансформации агропромышленного комплекса. Несмотря на существующие трудности, связанные с качеством данных, высокой стоимостью внедрения и необходимостью адаптации алгоритмов, дальнейшее совершенствование глубоких моделей, интеграция мультимодальных источников информации и повышение интерпретируемости систем создают предпосылки для формирования надёжных и масштабируемых инструментов мониторинга здоровья растений.

Библиографический список

1. Ferentinos K.P Deep learning models for plant disease detection and diagnosis [Электронный ресурс] // Computers and Electronics in Agriculture. – 2018. – Vol. 144. – Р. 311-318. – URL: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917311742> (дата обращения: 22.10.2025).
2. Mohanty S.P., Hughes D.P. and Salathé M. Using Deep Learning for Image-Based Plant Disease Detection [Электронный ресурс] // Front. Plant Sci. – 2016. – Vol. 7. – URL: <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2016.01419/full> (дата обращения 20.10.2025).
3. Зарипова Д. Н., Шлеймович М. П. Применение свёрточных нейронных сетей (CNN) для детекции объектов на аэроснимках // Вестник науки. 2025. №5 (86). URL: <https://cyberleninka.ru/article/n/primenie-svyortochnyh-neyronnyh-setey-cnn-dlya-detektsii-obektov-na-aerosnimkah> (дата обращения: 22.10.2025).

4. Ahmad A., Saraswat D., Gamal A.E. A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools [Электронный ресурс] // Smart Agricultural Technology. – 2023. – Vol. 3. – URL: <https://www.sciencedirect.com/science/article/pii/S277237552200048X> (дата обращения 22.10.2025)

5. Романцева, Ю. Н. Автоматизация анализа и прогнозирования развития аграрного сектора региона в среде r / Ю. Н. Романцева, А. М. Бодур, А. Б. Малина // Инфокоммуникационные технологии. – 2024. – Т. 22, № 2(86). – С. 94-102. – DOI 10.18469/ikt.2024.22.2.10. – EDN HEMORD.

6. Козлов, К. А. Подход к представлению данных специализированных статистических наблюдений по личным подсобным хозяйствам / К. А. Козлов, А. В. Уколова // Экономика сельского хозяйства России. – 2023. – № 10. – С. 81-92. – DOI 10.32651/2310-81. – EDN QOCUGZ.

7. Анализ динамики воспроизводства в сельском хозяйстве России за санкционный период / А. Г. Ибрагимов, В. В. Демичев, В. В. Маслакова [и др.] // Известия Тимирязевской сельскохозяйственной академии. – 2024. – № 5. – С. 153-167. – DOI 10.26897/0021-342X-2024-5-153-167. – EDN TLMDZM.

УДК 004.032.26

ОСОБЕННОСТИ РЕШЕНИЯ ПРОБЛЕМЫ ПЕРЕОБУЧЕНИЯ МОДЕЛИ НЕЙРОННОЙ СЕТИ МЕТОДОМ DROPOUT

Клушин Александр Сергеевич, студент 4 курса бакалавриата института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, aleksandr.klushin47@gmail.com

Рязанкин Кирилл Александрович, студент 4 курса бакалавриата института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, ryazankin.difors@yandex.ru

Дашеева Баярма Шагдаровна, к.э.н., доцент кафедры статистики и кибернетики ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, dashieva.b.sh@rgau-msha.ru

Аннотация. Переобучение остаётся одной из основных проблем глубоких нейронных сетей: модель демонстрирует высокие результаты на обучающих данных, но снижает точность на новых. В работе показано, как выявлять признаки переобучения и как регуляризация Dropout уменьшает зависимость сети от отдельных нейронов, улучшая её способность к обобщению.

Ключевые слова: нейронные сети, переобучение, регуляризация, Dropout, Keras.

FEATURES OF ADDRESSING NEURAL NETWORK OVERRFITTING USING THE DROPOUT METHOD

Klushin Alexander Sergeevich, 4th-year Bachelor's Student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU-MSHA), aleksandr.klushin47@gmail.com

Ryazankin Kirill Aleksandrovich, 4th-year Bachelor's Student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU-MSHA), ryazankin.difors@yandex.ru

Dashieva Bayarma Shagdarovna, Candidate of Economic Sciences, Associate Professor, Department of Statistics and Cybernetics, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU-MSHA), dashieva.b.sh@rgau-msha.ru

Abstract. Overfitting remains one of the primary challenges in deep neural networks: a model achieves high performance on training data but exhibits reduced accuracy on new, unseen data. This paper demonstrates how to identify signs of overfitting and explains how Dropout regularization reduces the network's reliance on individual neurons, thereby enhancing its generalization capability.

Keywords: neural networks, overfitting, regularization, Dropout, Keras.

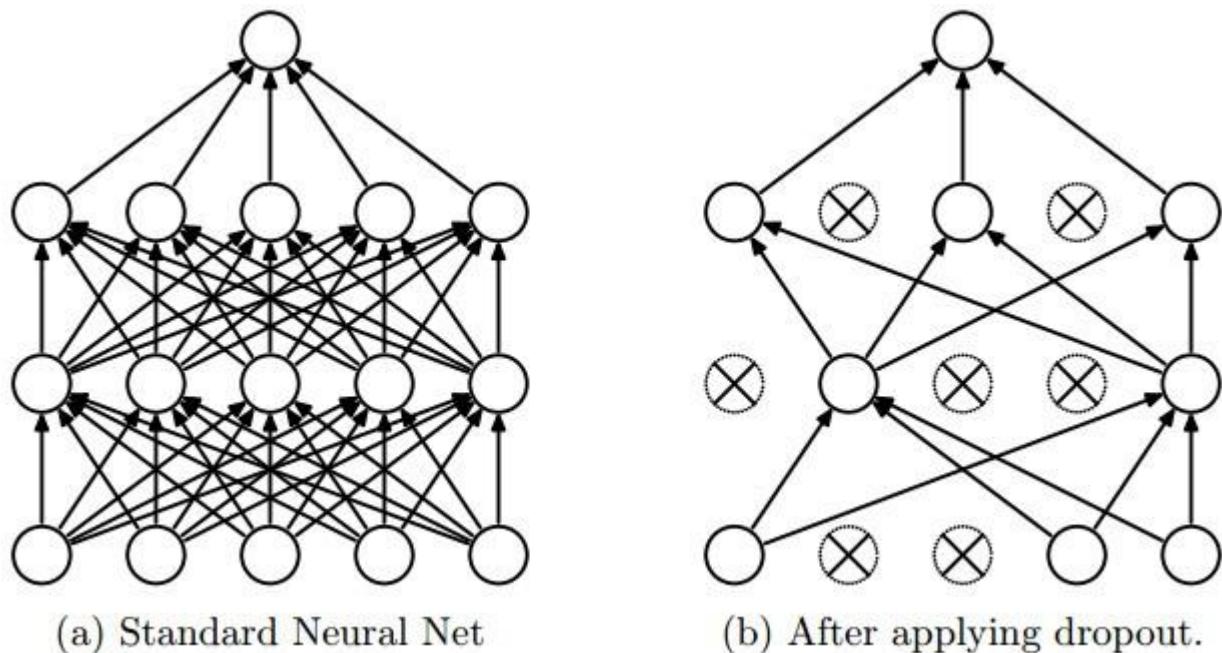
Одной из ключевых трудностей в машинном обучении является переобучение. Оно происходит, когда модель становится излишне чувствительной к случайным шумам и частным случаям в обучающих данных, вместо того чтобы выявлять общие, устойчивые закономерности. Модель демонстрирует блестящие результаты на известных ей данных, но её эффективность заметно падает при работе с новой информацией. В контексте глубоких нейросетей, обладающих огромным количеством настраиваемых параметров, риск переобучения особенно высок, если в распоряжении исследователя недостаточно данных. Для решения этой проблемы применяются различные методы, такие как расширение обучающего набора, штрафование излишне больших весов, ранняя остановка обучения и использование стохастических алгоритмов. Подробный обзор этих подходов можно найти в работах по регуляризации в глубоком обучении [3, 4].

Практически переобучение обнаруживается по нескольким объективным признакам:

- расхождение между тренировочной и валидационной потерями (training loss продолжает падать, validation loss – начинает расти) [1];
- тренд валидационной точности (val accuracy) выходит на плато или падает, тогда как train accuracy приближается к 100%;

- высокая дисперсия метрик при повторных запусках (нестабильность обобщения).

Dropout – метод стохастической регуляризации, предложенный в практической форме для глубоких сетей как способ предотвратить «коадаптацию» нейронов: на каждой итерации обучения случайно "выключается" (обнуляется) часть нейронов с фиксированной вероятностью p [2]. В результате сеть вынуждена распределять представления по множеству узлов, а не полагаться на небольшой набор сильных связей; это эквивалентно усреднению множества модельных конфигураций при сравнительно малой вычислительной стоимости. При выводе все нейроны включены, а их выходы масштабируются таким образом, чтобы ожидание активаций совпадало с тренировочным режимом [5].



Источник: Srivastava Nitish, и др. "Dropout: a simple way to prevent neural networks from overfitting", JMLR 2014 [6].

Рисунок 1 – Графическое представление метода Dropout

Ниже – код для демонстрации эффекта Dropout на датасете PlantVillage [7]. PlantVillage – это открытый датасет изображений листьев сельскохозяйственных культур, предназначенный для задач компьютерного зрения в агропромышленном комплексе. Набор данных состоит из 61 486 изображений здоровых и нездоровых листьев, разделенных на 39 категорий по видам и заболеваниям.

```

# Загрузка и подготовка данных
dataset, info = tfds.load('plant_village', as_supervised=True, with_info=True)

train_ds = dataset['train']

# train/test (80/20)
train_size = int(0.8 * info.splits['train'].num_examples)
train_ds = train_ds.take(train_size)
test_ds = dataset['train'].skip(train_size)

# Преобразование изображений
def preprocess(image, label):
    image = tf.image.resize(image, [64, 64]) / 255.0
    return image, label

train_ds = train_ds.map(preprocess).batch(128).shuffle(1000)
test_ds = test_ds.map(preprocess).batch(128)

num_classes = info.features['label'].num_classes
input_shape = (64, 64, 3)

# Модель с Dropout
model_dropout = Sequential([
    Flatten(input_shape=input_shape),
    Dense(512, activation='relu'),
    Dropout(0.5),
    Dense(512, activation='relu'),
    Dropout(0.5),
    Dense(num_classes, activation='softmax')
])

model_dropout.compile(optimizer='adam',
                      loss='sparse_categorical_crossentropy',
                      metrics=['accuracy'])

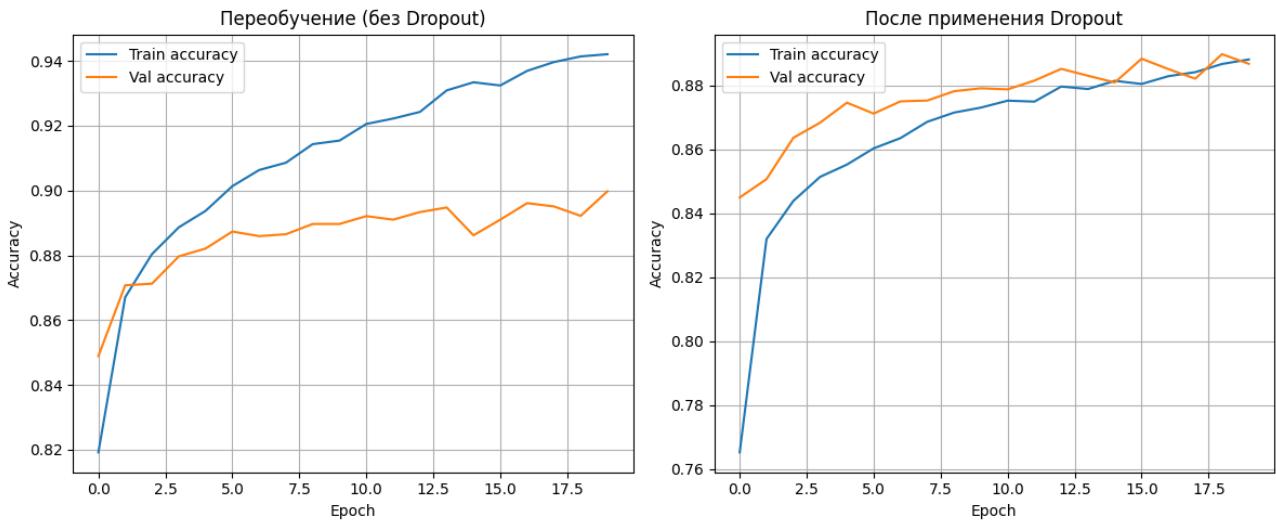
history_dropout = model_dropout.fit(
    train_ds,
    epochs=10,
    validation_data=test_ds,
    verbose=1
)

```

Источник: разработано авторами по данным [7]

Рисунок 2 – Пример реализации Dropout

В Keras Dropout реализован как слой, который во время обучения обнуляет входные единицы с заданной частотой rate, а при предсказании автоматически отключается. Для воспроизводимости также важно фиксировать seed и контролировать батч-size и оптимизатор (например, adam).



Источник: построено авторами по данным [7]

Рисунок 3 – Сравнение точности модели до и после применения Dropout

При сравнении двух моделей наблюдается следующая закономерность:

- без Dropout – модель быстро достигает высокой точности на обучающей выборке, однако точность на валидации начинает стагнировать или снижаться, что указывает на переобучение;

• с Dropout – обучение идёт медленнее, разрыв между train и val accuracy заметно уменьшается, это говорит о лучшей обобщающей способности модели;

Dropout остаётся простым, надёжным и вычислительно эффективным инструментом для уменьшения переобучения в нейронных сетях. На бенчмарках типа PlantVillage эффект Dropout хорошо иллюстрируется: сеть с регуляризацией показывает меньший разрыв между тренировочной и валидационной метриками и, как правило, лучшую обобщающую способность. Современные исследования продолжают анализировать вариации метода и его связь с другими видами регуляризации; на практике его рекомендуется использовать как часть набора регуляризационных техник, подбирая параметры валидацией.

Библиографический список

1. Галушкин, А. И. Нейронные сети // Большая российская энциклопедия / гл. ред. Ю. С. Осипов. Москва, 2013. – Т. 22. – С. 300-301.
2. Джулли, А. Библиотека Keras – инструмент глубокого обучения: Реализация нейронных сетей с помощью библиотек Theano и TensorFlow / А. Джулли, С. Пал. – Москва: ДМК Пресс, 2018. – 294 с.
3. Шолле, Ф. Глубокое обучение на Python. Санкт-Петербург [и др.]: Питер, 2018. – 397 с.
4. Бадика, Е. М. Проблема переобучения нейронных сетей. Способы устранения переобучения / Е. М. Бадика, З. В. Марченков // Инновационные идеи молодых исследователей: Сборник научных статей по материалам VI Международной научно-практической конференции, Уфа, 12 октября 2021 года. – Уфа: Общество с ограниченной ответственностью «Научно-издательский центр «Вестник науки», 2021. – С. 236-243. – EDN FPHIBK.

5. Пырнова, О. А. Методы и проблемы переобучения многослойной нейронной сети / О. А. Пырнова, Р. С. Зарипова // Информационные технологии в строительных, социальных и экономических системах. – 2020. – № 2(20). – С. 101-102. – EDN FZQBTP.

6. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. Dropout: a simple way to prevent neural networks from overfitting // Journal of Machine Learning Research. – 2014. – Vol. 15, No. 1. – P. 1929–1958.

7. J, ARUN PANDIAN; GOPAL, GEETHARAMANI (2019), “Data for: Identification of Plant Leaf Diseases Using a 9-layer Deep Convolutional Neural Network”, Mendeley Data, V1, doi: 10.17632/tywbtsjrv.1. – URL: <https://data.mendeley.com/datasets/tywbtsjrv/1>

УДК: 338.24:004.75

ОПТИМИЗАЦИЯ БИЗНЕС-ПРОЦЕССОВ В МИКРОБИЗНЕСЕ

Кокорева Владислава Андреевна, студентка 3 курса института Экономики и Управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева.

Научный руководитель – Демичев Вадим Владимирович, доцент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева.

Аннотация: В статье рассматриваются проблемы цифровизации малого бизнеса на примере индивидуального предпринимателя, занимающегося производством и продажей могильных сооружений. Анализируются типичные «узкие места»: потеря заявок, неэффективная коммуникация и хаотичный документооборот. Предлагается конкретное решение в виде внедрения облачной CRM-системы и разработки внутреннего регламента, что позволяет значительно повысить прозрачность, управляемость и скорость выполнения заказов.

Ключевые слова: CRM-система, анализ, микробизнеса, база, риски

BUSINESS PROCESS OPTIMIZATION IN MICROBUSINESS

Vladislava Andreevna Kokoreva, 3rd-year student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA)

Scientific Supervisor: V. V. Demichev, Associate Professor, Department of Statistics and Cybernetics, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA)

Abstract: This article addresses the challenges of digital transformation in small business, using the case of an individual entrepreneur engaged in the production and sale of grave monuments. Typical bottlenecks are analyzed, including lost customer inquiries, inefficient communication, and disorganized documentation workflows. A practical solution is proposed—implementing a cloud-based CRM system and developing an internal operational procedure—which significantly enhances transparency, controllability, and order fulfillment speed.

Keywords: CRM system, business analysis, microbusiness, customer database, operational risks

Любой бизнес, даже самый небольшой, сталкивается с необходимостью систематизации процессов по мере роста. Когда количество заказов, клиентов и сотрудников переходит определенный порог, работа «в уме» и на бумажках становится главным тормозом развития. Типичные симптомы:

1. Потерянные заявки: клиент звонил, но менеджер был занят, и звонок не был записан.

2. Хаос в коммуникации: обсуждение проекта ведется в WhatsApp, почте и по телефону одновременно, часть правок теряется.

3. Непрозрачность этапов: непонятно, на каком этапе находится каждый заказ, что уже сделано, а что нет.

Именно с такими проблемами столкнулось ИП «Кокорев» в ходе анализа его деятельности.

До внедрения изменений работа в компании строилась следующим образом:

1. Учет клиентов: В Excel-таблице или вовсе в блокноте.

2. Коммуникация: Личные телефоны менеджеров, общая почта и мессенджеры.

Эта система создавала множество рисков: увольнение одного менеджера могло привести к потере базы клиентов, ошибка в версии макета – к браку в производстве. Для новых сотрудников было проблематично настроится на работу, приходилось перелистывать предыдущие чаты для поиска информации, обращаться несколько раз к другим сотрудникам и ждать их ответа, если другой был занят. Это сильно тормозило процесс, даже для тех, кто занимал должности на этой компании несколько лет.

Было принято решение о комплексном подходе, включающем не только внедрение софта, но и формализацию правил его использования.

После анализа рынка для микробизнеса была выбрана облачная CRM-система Bitrix24 (как один из наиболее доступных и функциональных вариантов с бесплатным тарифом для небольшой команды).

Bitrix24 – это онлайн-сервис, в котором собраны все нужные инструменты для работы компании и управления бизнесом. Его мы выбрали из-за легкости его изучения и внедрения. Интерфейс не сильно перегружен для людей, которым тяжело адаптироваться к новой среде переходя из Excel или Word и его можно самостоятельно настроить для лучшего понимания системы.

Что это дало:

1. Управление сделками: Каждая заявка от клиента проходит по этапам воронки продаж. Рабочий процесс контролируется легче, нет задержек, и он строится прозрачнее за счет легкой доступности информации.

2. Задачи и поручения: Внезапных звонков и криков через весь цех: постановка задач на утверждение макета, закупку материала или подготовку документации происходит прямо в карточке сделки. Ответственный и сроки всегда известны.

3. Bitrix24 позволяет интеграции с другими сервисами и приложениями, в особенности, хочется отметить подключение с различными телефонными операторами. Большая часть коммуникации происходит лично, либо через связь. Это облегчило построение отчетов, нужных другими сотрудниками: тем, кто по какой-то причине не мог присутствовать на месте для диалога, или если коммуникация была построена только двумя отделами и нужно было сохранить диалог для доступа другими отделами.

4. Интеграция со службами доставки так же значительно облегчило процесс планирования.

Библиографический список

1. Федеральный закон от 27.07.2006 № 152-ФЗ «О персональных данных» (ред. от 01.03.2021) [Электронный ресурс]. – Режим доступа: http://www.consultant.ru/document/cons_doc_LAW_61801/ (Дата обращения: 15.09.2025).
2. Федеральный закон от 27.07.2006 № 149-ФЗ «Об информации, информационных технологиях и о защите информации» [Электронный ресурс]. – Режим доступа: http://www.consultant.ru/document/cons_doc_LAW_61798/ (Дата обращения: 15.09.2025).
3. Постановление Правительства РФ от 23.12.2015 № 1414 (ред. от 07.11.2020) «О порядке функционирования единой информационной системы в сфере закупок» [Электронный ресурс]. – Режим доступа: http://www.consultant.ru/document/cons_doc_LAW_191826/ (Дата обращения: 15.09.2025).
4. Савельев А.И. Договорно-правовые аспекты использования click-wrap соглашений в Российской Федерации // Вестник гражданского права. – 2025. – № 2.
5. Комбарова В.С. Правовое регулирование цифровых платформ // ИС. Авторское право и смежные права. – 2025. – № 3.
6. Ветошкин, А. Ю. Опыт реализации программ профессиональной переподготовки в аграрном вузе в рамках проекта "Цифровые кафедры" / А. Ю. Ветошкин // Всемирный день качества – 2023 : Материалы IV Международной конференции, Саратов, 08 ноября 2023 года. – Саратов: Саратовский государственный медицинский университет им. В.И. Разумовского, 2023. – С. 78-85. – EDN EOWDGA.
7. Ветошкин, А. Ю. Разработка веб-сайта "#Тиморганик" для популяризации органической продукции / А. Ю. Ветошкин // Материалы международной научно-практической конференции "Тренды развития

сельского хозяйства и агрообразования в парадигме Зеленой экономики" : сборник статей, Москва, 14–15 июня 2023 года. – Москва: Российский государственный аграрный университет- Московская сельскохозяйственная академия им. К.А. Тимирязева, 2023. – С. 12-17. – EDN JBORIL.

8. Статистический анализ импортозамещения продукции сельского хозяйства в России / М. В. Кагирова, В. В. Демичев, В. С. Токарев, К. А. Лебедев // Бухучет в сельском хозяйстве. – 2022. – № 7. – С. 514-524. – DOI 10.33920/sel-11-2207-05. – EDN XBWUED.

9. Свидетельство о государственной регистрации программы для ЭВМ № 2023683324 Российской Федерации. «Система управления веб-сайтом для реализации органических кормов для животных» : № 2023682448 : заявл. 26.10.2023 : опубл. 07.11.2023 / Н. Ф. Зарук, М. В. Кагирова, Ю. Н. Романцева [и др.] ; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет - МСХА имени К.А. Тимирязева». – EDN IBTKLC.

10. Семенова, С. О. Разработка web-приложения для реализации натуральных кормов / С. О. Семенова // Столыпинский вестник. – 2023. – Т. 5, № 8. – DOI 10.55186/27131424_2023_5_8_7. – EDN CCUEFW.

УДК 004.032.26:63

КОМПЬЮТЕРНОЕ ЗРЕНИЕ В СЕЛЬСКОМ ХОЗЯЙСТВЕ

Кошенков Денис Васильевич, студент 4 курса бакалавриата института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, tim.koshenkov@gmail.com

Руссу Андрей Максимович, студент 4 курса бакалавриата института экономики и управления АПК, ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, royfrommirom@mail.ru

Научный руководитель – Титов Артем Денисович, ст. преп., кафедра статистики и кибернетики ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, a.titov@rgau-msha.ru

Аннотация. В статье рассмотрено применение технологий компьютерного зрения в сельском хозяйстве как одного из ключевых направлений цифровизации аграрного сектора. Описаны принципы работы нейронных сетей, виды компьютерного зрения и их практическое использование в растениеводстве и животноводстве. Проведён анализ преимуществ и ограничений технологии, а также определены перспективы её дальнейшего развития в контексте интеграции с системами интернета вещей и большими данными.

Ключевые слова: компьютерное зрение, нейронные сети, искусственный интеллект, цифровизация, сельское хозяйство, автоматизация, анализ изображений.

COMPUTER VISION IN AGRICULTURE

Koshenkov Denis Vasilevich, 4th year student of faculty «Economics and management IAC» in Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, Moscow, Russia (127434, Moscow, Timiryazevskaya street 49), tim.koshenkov@gmail.com

Russu Andrey Maximovich, 4th year student of faculty «Economics and management IAC» in Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, Moscow, Russia (127434, Moscow, Timiryazevskaya street 49), royfrommurom@mail.ru

Scientific supervisor – Titov Artem Denisovich, Senior Lecturer, Department of Statistics and Cybernetics in Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, Moscow, Russia (127434, Moscow, Timiryazevskaya street 49), a.titov@rgau-msha.ru

Abstract. The article examines the application of computer vision technologies in agriculture as one of the key areas of digital transformation in the agricultural sector. It describes the principles of neural network operation, types of computer vision, and their practical use in crop and livestock production. The paper analyzes the advantages and limitations of the technology and outlines its future development prospects in the context of integration with the Internet of Things and big data systems.

Key words: computer vision, neural networks, artificial intelligence, digitalization, agriculture, automation, image analysis.

Введение. В последние годы сельское хозяйство переживает период активной цифровизации, направленной на повышение производительности, устойчивости и эффективности аграрных процессов. Быстрое развитие информационных технологий и внедрение автоматизированных систем позволяют решать задачи, ранее требовавшие значительных трудовых и временных ресурсов. Одним из ключевых направлений цифровой трансформации агросектора является применение технологий искусственного интеллекта, которые обеспечивают анализ больших объёмов данных и принятие обоснованных решений на их основе.

Особое место среди таких технологий занимает компьютерное зрение – инструмент, позволяющий машинам «видеть» и интерпретировать визуальную информацию, подобно человеку [1]. Благодаря этому становятся возможными автоматический мониторинг состояния растений и животных, контроль качества продукции, а также точное управление технологическими процессами. Использование компьютерного зрения в сельском хозяйстве способствует

повышению эффективности производства, сокращению издержек и улучшению экологической устойчивости отрасли, что делает данное направление актуальным и перспективным для дальнейших научных и практических исследований.

В настоящее время технологии компьютерного зрения находят применение в самых разных областях аграрного производства – от растениеводства до животноводства и переработки продукции. С их помощью осуществляется автоматический сбор и анализ визуальных данных, позволяющий оперативно выявлять болезни растений, контролировать качество урожая, оценивать степень зрелости плодов и прогнозировать урожайность. Использование дронов и специализированных камер даёт возможность проводить мониторинг больших площадей с высокой точностью, а интеграция с системами машинного обучения обеспечивает постоянное совершенствование моделей распознавания.

Цель данной статьи заключается в рассмотрении существующих подходов и решений, основанных на технологиях компьютерного зрения, применяемых в сельском хозяйстве. В рамках работы проводится анализ их практического использования, выделяются ключевые преимущества и ограничения, а также определяются перспективные направления дальнейшего развития этой технологии.

Основная часть. Нейронные сети представляют собой основу большинства современных технологий искусственного интеллекта, включая компьютерное зрение [2]. По своей структуре они имитируют работу человеческого мозга, состоящего из взаимосвязанных нейронов, каждый из которых передаёт и обрабатывает сигналы. Искусственные нейронные сети состоят из множества слоёв – входного, скрытых и выходного, – которые последовательно преобразуют данные, выявляя закономерности и формируя прогнозы. При обучении сеть анализирует большие объёмы информации и настраивает свои внутренние параметры (веса связей) так, чтобы минимизировать ошибку распознавания. Этот процесс, называемый глубоким обучением, особенно эффективен при обработке изображений, поскольку позволяет системе самостоятельно извлекать ключевые признаки объектов – форму, цвет, текстуру и пространственные взаимосвязи.

Компьютерное зрение, в свою очередь, является одной из прикладных областей искусственного интеллекта, целью которой является автоматизация восприятия и интерпретации визуальной информации. Его основная задача – научить компьютер «видеть» и понимать содержимое изображений или видеопотоков. В основе работы таких систем лежит несколько ключевых этапов: получение изображения с помощью камер или сенсоров, предварительная обработка (нормализация, фильтрация, выделение контуров), выделение признаков и последующая классификация объектов. Нейронные сети – особенно сверточные (Convolutional Neural Networks, CNN) – обеспечивают высокую точность в этих процессах, так как способны

распознавать сложные паттерны и обобщать их на новых данных. В рамках компьютерного зрения существует несколько направлений, различающихся по способу восприятия и обработки визуальной информации.

В сельском хозяйстве наибольшее практическое значение имеют те виды, которые позволяют получать разносторонние данные о состоянии растений, животных и окружающей среды. Среди них особое место занимают оптическое (визуальное), термовизионное (инфракрасное), а также объектное и метрическое зрение, каждое из которых решает свой круг задач и дополняет другие технологии в единой системе анализа [3].

Объектное и метрическое зрение представляют собой направление компьютерного зрения, ориентированное на распознавание, классификацию и количественную оценку объектов в пространстве. Объектное зрение позволяет системе не просто «видеть» изображение, но и определять, какие именно объекты на нём присутствуют, где они расположены и в каком они состоянии. На практике это реализуется через алгоритмы обнаружения объектов и сегментации изображений, которые определяют границы и контуры предметов. Метрическое зрение, в свою очередь, дополняет этот процесс измерением физических параметров – расстояния, площади, объёма и размеров объектов. В сельском хозяйстве такие технологии применяются для подсчёта плодов на деревьях, оценки урожайности, измерения биомассы растений, а также для контроля роста животных. Сочетание объектного и метрического анализа позволяет автоматизировать трудоёмкие операции и обеспечивает высокую точность оценки состояния сельскохозяйственных объектов.

Инфракрасное зрение основано на регистрации теплового излучения, исходящего от объектов. В отличие от обычных камер, фиксирующих свет в видимом спектре, инфракрасные сенсоры измеряют распределение температуры на поверхности растений, почвы или животных. Такие данные позволяют выявлять аномалии, невидимые человеческому глазу: стрессовые состояния растений, недостаток влаги, начало заболеваний или перегрев животных. В растениеводстве термокамеры используются для контроля орошения и оптимизации водных ресурсов, а в животноводстве – для ранней диагностики воспалительных процессов. Преимущество термовизионного анализа заключается в его универсальности и независимости от освещения, что делает его особенно эффективным при круглосуточном мониторинге.

Каждый из рассмотренных видов компьютерного зрения выполняет свои функции и решает специфические задачи, однако их объединяет общая цель – повышение эффективности и точности сельскохозяйственного производства. Комплексное применение этих технологий позволяет формировать целостное представление о состоянии агроэкосистем и оперативно реагировать на изменения внешних факторов. Вместе с тем, как и любая инновационная технология, компьютерное зрение обладает рядом преимуществ и ограничений, которые необходимо учитывать при его внедрении и эксплуатации.

Основным преимуществом применения компьютерного зрения в сельском хозяйстве является существенное повышение точности и скорости анализа данных, что позволяет принимать решения на основе объективных, а не

субъективных наблюдений. Благодаря автоматизации процессов мониторинга и диагностики удаётся значительно сократить потребность в ручном труде, а значит – снизить производственные издержки и минимизировать влияние человеческого фактора. [4] Кроме того, использование интеллектуальных систем способствует повышению урожайности, более рациональному расходу ресурсов и улучшению качества продукции. Не менее важно и то, что компьютерное зрение позволяет осуществлять постоянный контроль за состоянием сельскохозяйственных объектов в реальном времени, что особенно актуально при больших объёмах производства.

В то же время внедрение подобных технологий сопровождается определёнными трудностями. Прежде всего, это высокая стоимость оборудования, камер и вычислительных систем, необходимых для обработки данных. Кроме того, эффективность работы алгоритмов напрямую зависит от качества исходных изображений и стабильности внешних условий, таких как освещение или погодные факторы. Существенным ограничением остаётся и необходимость наличия квалифицированных специалистов, способных настраивать и обучать системы. Тем не менее, по мере развития технологий и снижения их стоимости данные проблемы постепенно утрачивают свою значимость, что открывает путь к более широкому и доступному применению компьютерного зрения в аграрном секторе.

Несмотря на существующие трудности, развитие технологий компьютерного зрения не останавливается, а, напротив, набирает всё большую динамику. Постепенное удешевление оборудования, совершенствование алгоритмов машинного обучения и интеграция с другими цифровыми решениями делают эту технологию всё более доступной для сельского хозяйства. В связи с этим особый интерес представляет рассмотрение перспектив её дальнейшего развития и тех направлений, в которых компьютерное зрение способно оказать наибольшее влияние на трансформацию аграрной отрасли в ближайшие годы.

В ближайшие годы развитие компьютерного зрения в сельском хозяйстве будет тесно связано с интеграцией данной технологии с другими элементами цифровой экосистемы – такими как интернет вещей, большие данные и автономные системы. Благодаря этому агропроизводство станет более предсказуемым и управляемым, а решения будут приниматься на основе комплексного анализа данных, поступающих от множества источников в режиме реального времени. Всё большее распространение получат беспилотные дроны и наземные роботы, оснащённые интеллектуальными системами визуального анализа, способные самостоятельно проводить обследование полей, выявлять очаги заболеваний и выполнять точечную обработку посевов.

Кроме того, значительное внимание будет уделяться развитию гиперспектрального и 3D-зрения, которые обеспечивают более глубокое понимание состояния растений и позволяют оценивать не только внешние признаки, но и внутренние биохимические процессы. Важным направлением станет и использование облачных вычислений, обеспечивающих хранение и

обработку больших объёмов изображений, что повысит точность и скорость анализа. Таким образом, в будущем компьютерное зрение станет неотъемлемой частью интеллектуальных систем управления сельским хозяйством, обеспечивая устойчивое, экономичное и экологически сбалансированное производство.

Заключение. В результате проведённого анализа можно сделать вывод, что технологии компьютерного зрения занимают важное место в процессе цифровой трансформации сельского хозяйства. Их внедрение способствует автоматизации ключевых производственных процессов, повышению точности и скорости анализа, а также снижению зависимости от человеческого фактора. Применение компьютерного зрения позволяет эффективно решать задачи мониторинга состояния растений и животных, контроля качества продукции и прогнозирования урожайности, что делает его одним из наиболее перспективных инструментов для построения «умного» земледелия.

Несмотря на существующие ограничения, связанные с высокой стоимостью оборудования, сложностью настройки систем и зависимостью от внешних условий, развитие нейронных сетей и совершенствование методов обработки изображений постепенно устраняют эти барьеры. Современные тенденции указывают на то, что интеграция компьютерного зрения с интернетом вещей, большими данными и роботизированными системами станет основой для формирования новой модели управления аграрным производством.

Библиографический список

1. Шамсутдинова, Т. М. Перспективы применения нейронных сетей в сельском хозяйстве / Т. М. Шамсутдинова // АгроЗооТехника. – 2024. – Т. 7, № 2. – С. 58–63.
2. Вашукевич, Е. Ю. Компьютерное зрение в сельском хозяйстве / Е. Ю. Вашукевич // Вестник Евразийской науки. – 2024. – Т. 16, № 6. – С. 112–118.
3. Осипова, Н. В. Перспективы применения цифровых технологий при земельном контроле и надзоре в аграрном секторе России / Н. В. Осипова // Современные проблемы науки и образования. – 2024. – № 3. – С. 93–99.
4. Салихова, М. Н. Нейронные сети в цифровом сельском хозяйстве / М. Н. Салихова // Информационные технологии и инновации. – 2022. – № 4. – С. 45–50.
5. Катков, Ю. Н. Информационно-аналитические инструменты обеспечения внешнеэкономической безопасности хозяйствующего субъекта / Ю. Н. Катков, И. А. Анохин // Информационно-аналитическое обеспечение устойчивого развития сельского хозяйства. – Москва : Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2023. – С. 111-158. – EDN VLDJIF.
6. Уколова, А. В. Типология личных подсобных хозяйств по данным всероссийской сельскохозяйственной переписи 2016 г / А. В. Уколова, Б. Ш. Дашиева // Экономика и управление: проблемы, решения. – 2022. – Т. 2, № 4(124). – С. 162-172. – DOI 10.36871/ek.up.p.r.2022.04.02.020. – EDN YRPKDV.

7. Демичев, В. В. Анализ предпосылок формирования аграрных кластеров / В. В. Демичев // Экономика сельского хозяйства России. – 2012. – № 2. – С. 58-65. – EDN OWMAVZ.

8. Уколова, А. В. Типология личных подсобных хозяйств по данным сельскохозяйственной микропереписи 2021 г / А. В. Уколова, К. А. Козлов // Экономика и управление: проблемы, решения. – 2024. – Т. 6, № 8(149). – С. 221-235. – DOI 10.36871/ek.up.p.r.2024.08.06.023. – EDN MNTLHJ.

9. Титов, А. Д. Анализ обеспеченности техникой сельского хозяйства Российской Федерации / А. Д. Титов // Сборник студенческих научных работ : по материалам докладов, 72-й Международной студенческой научно-практической конференции, посвященной 145-летию со дня рождения А.Г. Дояренко, Москва, 26–29 марта 2019 года. Том Выпуск 26. – Москва: Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2019. – С. 285-288. – EDN IXESMX.

УДК 004.83

ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ НА PYTHON КАК ИНСТРУМЕНТ ЦИФРОВИЗАЦИИ АПК

Кудрявцев Вадим Алексеевич, студент 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, vkudr03@gmail.com

Научный руководитель – Титов Артем Денисович, ассистент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, a.titov@rgau-msha.ru

Аннотация. Проведено ознакомление с нейронными сетями: для чего в АПК, почему Python, примеры применения.

Ключевые слова: нейронные сети, Python, искусственный интеллект, цифровизация

INTELLIGENT SYSTEMS IN PYTHON AS A TOOL FOR DIGITIZING THE AGRO-INDUSTRIAL COMPLEX

Vadim Alexeyevich Kudryavtsev, 4th-year student, Institute of Economics and Management in Agro-Industrial Complex,
Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA),
vkudr03@gmail.com

Scientific Supervisor: Artem Denisovich Titov, Assistant, Department of Statistics and Cybernetics,

Abstract. This paper provides an overview of neural networks—why they are relevant to the agro-industrial complex (AIC), why Python is the preferred programming language, and examples of their practical applications.

Keywords: neural networks, Python, artificial intelligence, digitization

Искусственный интеллект помогает аграрному сектору в его трансформации по средствам анализа больших данных, а также оптимизации процессов. Эти технологии повышают конкурентоспособность сельского хозяйства, снижают экологическую нагрузку, способствуют устойчивому развитию отрасли.

Возможности, которые представляют нейросети для фермеров обширны. Они обрабатывают данные с датчиков, установленных в теплицах, позволяя узнать влажность почвы, температуру и другие важные показатели, которые в свою очередь нужны для прогнозирования урожайности и оптимального планирования посевов. Алгоритмы, анализирующие изображения с дронов и спутников, помогают выявлять болезни растений, позволяя применять защитные меры. Алгоритмы прогнозирования также способствуют роботизации сельскохозяйственного автопарка и умных теплиц, обеспечивают распределение ресурсов и оптимальные условия для роста культур.

В качестве языка программирования при разработке нейронной сетей используется Python. Его использования обусловлено многочисленными библиотеками, которые помогают в построении сетей. Эти библиотеки – TensorFlow, которая используется для анализа больших данных, например, снимков со спутника, для прогноза урожайности [2]. PyTorch, непосредственно, помогает с разработкой сетей, которые могут использоваться для различных аналитических операций [3]. OpenCV, в свою очередь, используется для обработки изображений, полученных с дронов, спутников и так далее [4]. Эти вспомогательные инструменты, а также легкость синтакса, и делают Python ведущим языком, когда вопрос доходит до создания нейронных сетей.

Примером практического использования Python с его библиотеками может послужить разработка индийских коллег [1]. Так была разработана модель на основе TensorFlow и OpenCV для автоматической диагностики болезней по изображениям листьев различных сельскохозяйственных культур. Система, использующая сверточные нейронные сети, была обучена на большом наборе изображений. Это позволило ей определять заболевания культур с точностью 94,2%. OpenCV обеспечивала предварительную обработку снимков, улучшая их качество для последующего анализа. Анализ же проводился через нейросеть, написанной с помощью библиотеки TensorFlow.

Нейросети, несомненно, ускоряют цифровизация агропромышленного комплекса, а благодаря Python эта цифровая трансформация становится

доступна более широкому кругу лиц. Она также способствует переходу сельского хозяйства от реактивного способа управления к предиктивному.

Библиографический список

1. Dubey R., Sharma A., Khatri M. *Plants Disease Detection Using TensorFlow and OpenCV.* – *Journal of Emerging Electronics and Design Technology*, Vol. 11, Issue 3, 2024, pp. 45–53.
2. TensorFlow Documentation – *TensorFlow Core v2.16* [Электронный ресурс]. – URL: <https://www.tensorflow.org/>
3. PyTorch Documentation – *PyTorch 2.3.0* [Электронный ресурс]. – URL: <https://pytorch.org/docs/>
4. OpenCV Documentation – *OpenCV 4.x* [Электронный ресурс]. – URL: <https://docs.opencv.org/>
5. Бухгалтерский финансовый учет в сельском хозяйстве : Под общей редакцией Н.Г. Белова, Л.И. Хоружий / Н. Г. Белов, Л. И. Хоружий, Н. Н. Карзаева [и др.]. Том 2. – Москва : Российский государственный аграрный университет - Московская сельскохозяйственная академия им. К.А. Тимирязева, 2010. – 363 с. – ISBN 978-5-9675-0372-6. – EDN SIOOUF.
6. Хусаинова, А. С. Методические рекомендации по организации бухгалтерского учета в сельском хозяйстве в связи с принятием Федерального закона от 6 декабря 2011 г. № 402-ФЗ "О бухгалтерском учете" / А. С. Хусаинова, Н. Г. Белов, Л. И. Хоружий. – Москва : ФГБНУ «Росинформагротех», 2012. – 100 с. – EDN WPXRQL.
7. Быков, Д. В. Разработка информационной системы учета и обработки данных с поддержкой проведения статистического анализа на C++ / Д. В. Быков, А. В. Уколова // Электронный сетевой политехнический журнал "Научные труды КубГТУ". – 2022. – № 4. – С. 32-45. – EDN YNGFKF.
8. Храмов, Д. Э. Цифровые ресурсы как инструмент педагогики автономии в высшей школе / Д. Э. Храмов // Педагогическое взаимодействие: возможности и перспективы : Материалы VI международной научно-практической конференции, Саратов, 28–30 марта 2024 года. – Саратов: Саратовский государственный медицинский университет им. В.И. Разумовского, 2024. – С. 441-445. – EDN SIXVWL.

ПРИМЕНЕНИЕ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ВЫЯВЛЕНИЯ ВРЕДОНОСНОГО ПРОГРАММНОГО ОБЕСПЕЧЕНИЯ В IoT-УСТРОЙСТВАХ АГРОПРОМЫШЛЕННОГО КОМПЛЕКСА

Лапин Николай Германович, студент 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева,
lapinkolya44@mail.ru

Шеболдин Алексей Дмитриевич, студент 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева,
sheboldinalexey@gmail.com

Научный руководитель – Храмов Дмитрий Эдуардович, ассистент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, khramovde@rgau-msha.ru

Аннотация. В статье исследуются методы глубокого обучения для обнаружения вредоносного ПО в сетевом трафике IoT-устройств АПК на основе набора данных IoT-23. Рассмотрены модели CNN, LSTM и автоэнкодеры, а также методы предобработки и балансировки данных. Эксперименты показали, что глубокие нейросети достигают высокой точности ($F1 > 0.96$) при умеренных вычислительных затратах, что позволяет использовать их в инфраструктуре IoT АПК.

Ключевые слова: Интернет вещей, агропромышленный комплекс, кибербезопасность, глубокое обучение, нейронные сети, обнаружение вредоносного ПО, IoT-23, CNN, LSTM, автоэнкодер.

APPLICATION OF DEEP LEARNING METHODS FOR MALWARE DETECTION IN IoT DEVICES OF THE AGRICULTURAL SECTOR

Lapin Nikolay Germanovich, 4th-year student, Institute of Economics and Management of the Agro-Industrial Complex, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, lapinkolya44@mail.ru

Sheboldin Aleksey Dmitrievich, 4th-year student, Institute of Economics and Management of the Agro-Industrial Complex, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, sheboldinalexey@gmail.com

Scientific supervisor – Khramov Dmitry Eduardovich, Assistant of the Department of Statistics and Cybernetics, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, khramovde@rgau-msha.ru

Abstract. The article explores deep learning methods for detecting malware in the network traffic of IoT devices used in the agricultural sector, based on the IoT-23 dataset. CNN, LSTM, and autoencoder models, as well as data preprocessing and

class balancing techniques, are considered. The experiments demonstrate that deep neural networks achieve high accuracy ($F1 > 0.96$) with moderate computational costs, making them suitable for integration into the IoT infrastructure of the agricultural industry.

Keywords: Internet of Things, agricultural sector, cybersecurity, deep learning, neural networks, malware detection, IoT-23, CNN, LSTM, autoencoder.

Интернет вещей (IoT) стал ключевой технологией цифровизации агропромышленного комплекса. Современные теплицы, системы орошения, кормления и мониторинга состояния животных используют сеть датчиков и исполнительных устройств для оптимизации производственных процессов. Однако широкая связность, использование устаревших протоколов и слабая аутентификация делают такие системы мишенью для кибератак. Вредоносное ПО может вмешиваться в работу датчиков, подменять показания или создавать ботнет-сети, используемые для DDoS-атак.

Традиционные сигнатурные методы обнаружения, применяемые в системах IDS/IPS, не справляются с динамически изменяющимися угрозами и обfuscацией вредоносного кода [2]. Методы машинного обучения, а особенно глубокого обучения (Deep Learning, DL), позволяют выявлять скрытые закономерности в сетевом поведении устройств и определять новые типы атак без необходимости ручного обновления сигнатур [3].

Цель исследования – разработка и оценка эффективности архитектур глубокого обучения для обнаружения вредоносного ПО в IoT-устройствах агропромышленного комплекса [8].

Гипотеза – интеграция сверточных и рекуррентных моделей (CNN-LSTM) позволяет повысить точность и устойчивость систем обнаружения атак на IoT-сети АПК по сравнению с классическими ML-подходами при сопоставимых вычислительных требованиях.

Для обучения и тестирования моделей использовался открытый набор IoT-23, содержащий более 6 млн записей сетевых соединений между IoT-устройствами и внешними узлами [4]. Набор включает как «Benign» (нормальный трафик), так и вредоносные сценарии, характерные для реальных ботнетов: Okiru, DDoS, PartOfAHorizontalPortScan, C&C HeartBeat и другие. Эти сценарии типичны и для IoT-устройств в АПК, таких как сенсоры влажности и температуры, контроллеры полива, беспилотники и шлюзы данных.

Данные были очищены от дубликатов, категориальные признаки (протокол, сервис, направление трафика) закодированы, численные признаки нормализованы. Для борьбы с сильным дисбалансом классов использована стратегия комбинированного oversampling и undersampling, что позволило сформировать обучающую выборку с около 600 000 примеров на каждый класс.

Исследованы три типа моделей:

1. Сверточная нейронная сеть (CNN) – извлекает пространственные закономерности между признаками сетевого трафика [1]. Использовались свёртки 1D с шагом 2–3, ReLU-активация и dropout-регуляризация.

2. Рекуррентная сеть (LSTM) – учитывает временную зависимость пакетов в потоке, что важно для анализа последовательностей соединений [5]. Применялись двухслойные LSTM с 128 нейронами на слой.

3. Автоэнкодер (Autoencoder) – безметочный метод, обучающийся восстанавливать «нормальное» поведение и выявлять аномалии по ошибке реконструкции [6].

Также исследована гибридная CNN-LSTM архитектура, объединяющая преимущества пространственного и временного анализа [10].

Модели обучались на персональном компьютере, оснащённом видеокартой NVIDIA GeForce RTX 5060 (объём видеопамяти – 8 ГБ). Для оптимизации применялся алгоритм Adam с коэффициентом обучения learning rate = 0.001. Размер пакета данных составлял batch size = 512, количество эпох обучения – 50.

Для оценки использовались метрики Accuracy, Precision, Recall, F1-мера, ROC-AUC и каппа Кохена. Разбиение данных выполнялось в соотношении 80/20 между обучающей и тестовой выборками.

Модели глубокого обучения показали высокую способность различать нормальный и вредоносный трафик IoT-устройств [9].

Наилучшие результаты получены для CNN-LSTM, где:

1. Accuracy = 0.982.
2. Recall = 0.968.
3. F1-мера = 0.961.
4. ROC-AUC = 0.985.
5. Каппа Кохена = 0.94.

Для отдельных классов (например, «C&C HeartBeat») точность классификации превышала 97 %, тогда как на сложных случаях («PartOfAHorizontalPortScan») показатели снижались до 93–94 %, что указывает на высокую чувствительность модели при незначительных ошибках в близких по структуре сценариях. Подробные оценки производительности модели приведены на рисунке ниже (Рисунок 1):

```
print(classification_report(y_test, Y_pred, target_names=Y_label.classes_))

precision    recall   f1-score   support
Benign       0.99     0.98     0.98    137763
  DDoS        0.99     0.99     0.99    131152
  Okiru       1.00     1.00     1.00    262603
PartOfAHorizontalPortScan  0.98     1.00     0.99    200000

accuracy                           0.99
macro avg      0.99     0.99     0.99    731518
weighted avg   0.99     0.99     0.99    731518

# Оценить производительность модели на тестовом множестве данных
from sklearn.metrics import precision_recall_fscore_support

y_pred = model.predict(X_test)
precision, recall, f1, _ = precision_recall_fscore_support(y_test, y_pred, average='weighted', labels=[0, 1, 2, 3])
print('Precision:', precision)
print('Recall:', recall)
print('F1 score:', f1)

Precision: 0.9923055005953526
Recall: 0.9922777019840934
F1 score: 0.9922675658663452
```

Рисунок 1 – Оценки модели

CNN хорошо справляется с анализом устойчивых шаблонов пакетов, но теряет информацию о временной динамике. LSTM эффективно улавливает зависимость между последовательными соединениями, однако хуже работает с шумными признаками. Autoencoder позволяет выявлять ранее неизвестные типы атак (zero-day), демонстрируя чувствительность выше 0.9 на аномальных образцах. CNN-LSTM сочетает преимущества обоих типов сетей, показывая стабильность и высокие значения всех метрик.

При анализе активаций и attention-весов LSTM обнаружено, что ключевые признаки, влияющие на классификацию, – длительность сессии, количество пакетов в направлении клиента, частота SYN-пакетов и соотношение байтов вход/выход. Эти параметры соответствуют реальным индикаторам атак типа DDoS и сканирования портов в сетях АПК.

Сельское хозяйство активно внедряет IoT-технологии: интеллектуальные теплицы, метеостанции, датчики влажности почвы, GPS-трекеры скота и беспилотники. Компрометация таких систем способна вызвать экономические потери, снижение урожайности и нарушения логистики. Разработанные модели могут быть встроены в шлюзы сбора данных или периферийные серверы (edge-устройства) для реального-времени анализа сетевого трафика и раннего обнаружения аномалий.

Преимущества DL-подхода:

1. Автоматическое извлечение признаков без ручного отбора.
2. Устойчивость к вариациям трафика разных устройств и протоколов.
3. Возможность обучения на потоковых данных, что особенно актуально для распределённых IoT-систем АПК.
4. Масштабируемость – модели могут быть дообучены по мере появления новых угроз.

Несмотря на высокие результаты, DL-модели требуют значительных вычислительных ресурсов и достаточного количества размеченных данных. Для внедрения в инфраструктуру АПК необходимо разрабатывать облегчённые версии нейросетей (TinyDL, Quantized CNN), способные работать на микроконтроллерах и IoT-шлюзах. Перспективным направлением является федеративное обучение, позволяющее объединять данные с разных фермерских хозяйств без их централизованной передачи.

Исследование показало, что методы глубокого обучения – CNN, LSTM, Autoencoder и их комбинации – эффективно выявляют вредоносное ПО в сетевом трафике IoT-устройств агропромышленного комплекса. На наборе IoT-23 достигнуты высокие значения Accuracy > 0.98 и F1-меры > 0.96, что подтверждает применимость DL-подходов для построения интеллектуальных систем кибербезопасности в сельском хозяйстве.

Перспективы дальнейшей работы включают оптимизацию моделей для работы на ограниченных устройствах, разработку федеративных протоколов обучения и интеграцию детекторов в существующие платформы управления «умным» сельским хозяйством [7].

Библиографический список

1. Akhtar, M. Sh., Feng, T. (2022). Detection of Malware by Deep Learning as CNN-LSTM Machine Learning Techniques in Real Time. *Symmetry*, 14(11), 2308. <https://doi.org/10.3390/sym14112308>
2. Ali, R., Ali, A., Iqbal, F., Hussain, M., Ullah, F. (2022). Deep Learning Methods for Malware and Intrusion Detection: A Systematic Literature Review. *Security and Communication Networks*. DOI: 10.1155/2022/2959222
3. Ansam Khraisat, Ammar Alazab (2021). A critical review of intrusion detection systems in the Internet of Things: techniques, deployment strategy, datasets and challenges. *Cybersecurity*, 4(18). <https://doi.org/10.1186/s42400-021-00077-7>
4. Bendiab, G., Shiaeles, S., Alrurban, A., Kolokotronis, N. (2020). IoT malware network traffic classification using visual representation and deep learning. *Proceedings of the 6th IEEE Conference on Network Softwarization (NetSoft 2020)*, pp. 444–449. DOI: 10.1109/NetSoft48620.2020.9165381
5. Gopali, S., Namin, A. S. (2022). Deep Learning-Based Time-Series Analysis for Detecting Anomalies in Internet of Things. *Electronics*, 11(19), 3205. <https://doi.org/10.3390/electronics11193205>
6. Luo, X., Li, J., Wang, W., Gao, Y., Zhao, W. (2021). Towards improving detection performance for malware with a correntropy-based deep learning method. *Digital Communications and Networks*, 7, 570–579. DOI: 10.1016/j.dcan.2021.02.003
7. Or-Meir, O., Nissim, N., Elovici, Y., Rokach, L. (2019). Dynamic Malware Analysis in the Modern Era – A State-of-the-Art Survey. *ACM Computing Surveys*, 52(5), Article 88, 1–48. <https://doi.org/10.1145/3329786>
8. Гайфулина Д.А., Котенко И.В. (2021). Анализ моделей глубокого обучения для задач обнаружения сетевых аномалий Интернета вещей. *Информационно-управляющие системы*, (1), 28–37. <https://doi.org/10.31799/1684-8853-2021-1-28-37>
9. Котенко И.В., Хмыров С.С. (2022). Анализ моделей и методик, используемых для атрибуции нарушителей кибербезопасности при реализации целевых атак. *Вопросы кибербезопасности*, 4(50), 52–79. DOI: 10.21681/2311-3456-2022-4-52-79
10. Р.М. Ауси, Е.В. Заргарян, Ю.А. Заргарян (2023). Глубокое обучение методам защиты от атак. *Известия ЮФУ. Технические науки*, № 3 (2023). DOI: 10.18522/2311-3103-2023-2-227-239
11. Анохин, И. А. Формирование системы внешнеэкономической безопасности в организациях АПК / И. А. Анохин // Сборник трудов, приуроченных к 75-ой Всероссийской студенческой научно-практической конференции, посвященной 150-летию со дня рождения Е. А. Богданова, Москва, 14–17 марта 2022 года. – Москва: Общество с ограниченной ответственностью "Мегаполис", 2022. – С. 154-157. – EDN BADKZG.
12. Катков, Ю. Н. Информационно-аналитические инструменты обеспечения внешнеэкономической безопасности хозяйствующего субъекта / Ю. Н. Катков, И. А. Анохин // Информационно-аналитическое обеспечение устойчивого развития сельского хозяйства. – Москва : Российский

государственный аграрный университет - МСХА им. К.А. Тимирязева, 2023. – С. 111-158. – EDN VLDJIF.

13. Быков, Д. В. Разработка информационной системы учета и обработки данных с поддержкой проведения статистического анализа на C++ / Д. В. Быков, А. В. Уколова // Электронный сетевой политехнический журнал "Научные труды КубГТУ". – 2022. – № 4. – С. 32-45. – EDN YNGFKE.

14. Козлов, К. А. Подход к представлению данных специализированных статистических наблюдений по личным подсобным хозяйствам / К. А. Козлов, А. В. Уколова // Экономика сельского хозяйства России. – 2023. – № 10. – С. 81-92. – DOI 10.32651/2310-81. – EDN QOCUGZ.

УДК 004.83

РАЗРАБОТКА СИСТЕМЫ АВТОМАТИЧЕСКОЙ ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ РАСТЕНИЙ МЕТОДАМИ ГЛУБОКОГО ОБУЧЕНИЯ НА PYTHON

Маврин Андрей Маркович: студент 4 курса института экономики и управления АПК ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, superandrex@ mail.ru

Научный руководитель – Титов Артём Денисович, ассистент кафедры статистики и кибернетики института экономики и управления АПК ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, a.titov@rgau-msha.ru

Аннотация. В работе представлена система автоматической диагностики заболеваний растений на основе сверточных нейронных сетей. Разработанное решение осуществляет бинарную классификацию изображений листьев на категории «здоровые» и «больные». Система реализована на Python с использованием библиотек TensorFlow и Keras. Применен конвейер обработки данных с аугментацией и трансферным обучением на модели MobileNetV2. Достигнута точность классификации 98% на тестовой выборке.

Ключевые слова: глубокое обучение, компьютерное зрение, классификация изображений, диагностика заболеваний, сверточные нейронные сети, трансферное обучение.

DEVELOPMENT OF A DEEP LEARNING-BASED SYSTEM FOR AUTOMATED PLANT DISEASE DIAGNOSIS IN PYTHON

Andrei Markovich Mavrin, 4th-year student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), superandrex@ mail.ru

Scientific Supervisor: Artem Denisovich Titov, Assistant, Department of Statistics and Cybernetics, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), a.titov@rgau-msha.ru

Abstract. This paper presents an automated plant disease diagnosis system based on convolutional neural networks. The developed solution performs binary classification of leaf images into “healthy” and “diseased” categories. Implemented in Python using the TensorFlow and Keras libraries, the system employs a data processing pipeline featuring augmentation and transfer learning with the MobileNetV2 architecture. A classification accuracy of 98% was achieved on the test dataset.

Keywords: deep learning, computer vision, image classification, disease diagnosis, convolutional neural networks, transfer learning.

Введение. Сельскохозяйственный сектор сталкивается с серьезными проблемами потерь урожая из-за заболеваний растений. Традиционные методы диагностики часто недостаточно оперативны, что требует внедрения автоматизированных решений. Технологии компьютерного зрения на основе сверточных нейронных сетей позволяют эффективно автоматизировать процесс диагностики. Цель работы – разработка системы бинарной классификации изображений растений с использованием глубокого обучения.

Основная часть. Для исследования использовался набор данных с изображениями листьев растений, разделенных на категории «здоровые» и «больные». Данные требовали предобработки из-за вариативности размеров, освещенности и ракурсов съемки.

Система реализована на Python с использованием TensorFlow и Keras. Процесс разработки включал этапы загрузки данных, построения архитектуры сети, обучения и тест модели.

Для загрузки и аугментации данных применялся ImageDataGenerator из Keras. Аугментация включала случайные повороты, сдвиги и отражения изображений для повышения устойчивости модели.

В качестве базовой архитектуры использована предобученная модель MobileNetV2 с добавленными слоями GlobalAveragePooling2D, Dropout и Dense с сигмоидальной активацией. Модель компилирована с оптимизатором Adam и функцией потерь binary_crossentropy.

Обучение проводилось 15 эпох с применением callback-функций: ModelCheckpoint, EarlyStopping и ReduceLROnPlateau для предотвращения переобучения и оптимизации процесса обучения.

Разработанная система достигла точности 98% на тестовой выборке. Модель демонстрирует сбалансированные показатели precision (0.97-0.99) и recall (0.98-0.99) для обоих классов.

Заключение. Разработана система автоматической диагностики заболеваний растений, достигающая точности 98%. Использование

трансферного обучения и аугментации данных позволило создать эффективное решение для бинарной классификации. Система может быть интегрирована в мобильные приложения и системы мониторинга посевов. Перспективы развития включают расширение для мультиклассовой классификации и оптимизацию для мобильных устройств.

Библиографический список

1. TensorFlow Documentation: Keras API Reference [Электронный ресурс]. – 2023. – URL: https://www.tensorflow.org/api_docs/python/tf/keras (дата обращения: 4.10.2025).
2. PyTorch Documentation: Computer Vision [Электронный ресурс]. – 2023. – URL: <https://pytorch.org/vision/stable/index.html> (дата обращения: 3.10.2025).
3. Официальная документация библиотеки OpenCV [Электронный ресурс]. – 2023. – URL: <https://docs.opencv.org/> (дата обращения: 4.10.2025).
4. Бодур, А. М. Сельское хозяйство и изменение климата в рамках устойчивого развития / А. М. Бодур // Материалы II национальной научной конференции "Современные направления статистических исследований", Москва, 26 декабря 2023 года. – Москва: Российский государственный аграрный университет, 2024. – С. 14-22. – EDN JJVRJZ.
5. Демичев, В. В. Статистическое исследование инвестирования в сельское хозяйство России в условиях реализации государственных программ : монография / В. В. Демичев, В. В. Маслакова. – Иркутск : ООО "Мегапринт", 2017. – 162 с. – ISBN 978-5-907095-19-9. – EDN TUDTFV.

УДК: 004.8

ПОГОНЯ ЗА РАЗУМОМ: ЛУЧШИЕ ПОПЫТКИ СОЗДАНИЯ AGI

Маханьков Тимофей Максимович, студент 4 курса бакалавриата института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, makhankovtm@gmail.com

Научный руководитель – Невзоров Александр Сергеевич, старший преподаватель кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева, a.nevzorov@rgau-msha.ru

Аннотация. В статье рассматриваются ключевые аспекты: различия между слабым (*narrow*) ИИ, решающим узкие задачи без настоящего понимания, и сильным ИИ (*AGI*), обладающим универсальным интеллектом; роль больших языковых моделей (*LLM*) как наиболее перспективного пути к *AGI*; основные преграды, включая отсутствие самостоятельного обучения и метапознания; а также альтернативный подход – симуляция человеческого мозга.

Ключевые слова: сильный искусственный интеллект, AGI, большие языковые модели, *llm*, симуляция мозга, нейроморфная инженерия, ARC-AGI, технологическая сингularity, метапознание

THE RACE FOR INTELLIGENCE: THE BEST APPROACHES TO AGI

Makhankov Timofey Maksimovich, 4th year undergraduate student of the Institute of Economics and Management of the Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education "Russian State Agrarian University-Moscow Timiryazev Agricultural Academy", makhankovtm@gmail.com

Scientific supervisor – Alexander Sergeevich Nevzorov, senior lecturer at the Department of Statistics and Cybernetics, Complex, Federal State Budgetary Educational Institution of Higher Education "Russian State Agrarian University-Moscow Timiryazev Agricultural Academy", a.nevzorov@rgau-msha.ru

Abstract. This article examines key aspects: the differences between narrow AI, which solves narrow tasks without real understanding, and strong AI (AGI), which possesses universal intelligence; the role of large language models (LLM) as the most promising path to AGI; major obstacles, including the lack of autonomous learning and metacognition; and an alternative approach—human brain simulation.

Keywords: strong artificial intelligence, AGI, large language models, *llm*, brain simulation, neuromorphic engineering, ARC-AGI, technological singularity, metacognition

Характеристики AGI включают универсальность: система может перейти от решения математических задач к написанию поэзии или управлению роботом в неизвестной среде. Ключевые аспекты – самостоятельное обучение, метапознание и здравый смысл. Для оценки AGI используются тесты, такие как тест Тьюринга, где ИИ должен имитировать человека в разговоре так, чтобы судья не отличил его от человека. Однако тест Тьюринга критикуют за фокус на имитации, а не на понимании.

Большие языковые модели (Large Language Models, LLM) представляют собой один из самых динамичных и перспективных подходов к созданию AGI. Эти модели, основанные на обработке огромных объемов текстовых данных, демонстрируют впечатляющие способности к обобщению, адаптации и даже элементарному рассуждению, приближаясь к универсальности, характерной для AGI.

«Понимание» мира достигается через язык: модели захватывают семантику, синтаксис и причинно-следственные. Это позволяет им моделировать сложные концепции: в генерации кода LLM вроде GPT-4о могут писать программы на Python, исправляя ошибки на основе контекста. В переводах они учитывают нюансы, такие как идиомы, достигая точности >95% для распространенных языков. Креативный контент – истории, поэзия или

маркетинговые тексты – генерируются с учетом стиля, как в случае с Claude, создающим нарративы по запросу [1].

Успехи LLM значительны: в программировании они ускоряют разработку, генерируя код с точностью >80% для простых задач, как в Copilot. В медицине – поддержка диагностики, анализ записей и образование, с приложениями в клиническом уходе. Например, модели на базе GPT помогают в интерпретации рентгенов или рекомендациях лечения.

На данный момент LLM однозначный лидер в гонке за AGI благодаря масштабу и универсальности, но языковые модели сталкиваются с серьёзными преградами на этом пути.

Несмотря на впечатляющие достижения больших языковых моделей (LLM) и других подходов к искусственному интеллекту, путь к созданию искусственного общего интеллекта (AGI) усеян значительными преградами. Эти барьеры не только технические, но и фундаментальные, касающиеся природы самого интеллекта.

Одна из главных преград на пути к AGI – это зависимость современных ИИ-систем от предобученных данных, без возможности формировать собственный опыт или делать выводы за пределами обучающего набора. В отличие от человека, который активно исследует мир, экспериментирует и учится на ошибках в реальном времени, LLM и другие модели полагаются на пассивное поглощение огромных объемов статических данных. Это приводит к «*data hunger*» – необходимости в триллионах токенов для достижения приемлемой производительности, но даже тогда модели не могут генерировать новые знания самостоятельно [2].

Метапознание – способность осознавать свои знания, пробелы и уверенность в ответах – является ключевым атрибутом человеческого интеллекта, но полностью отсутствует в текущих ИИ-системах. LLM не «знают, что они знают», что приводит к галлюцинациям – генерации правдоподобных, но ложных фактов – и переоценке своей компетентности. Это делает их ненадежными для критических задач, где ошибка может иметь последствия.

Подходы к решению включают Retrieval-Augmented Generation (RAG), где модель запрашивает внешние источники для верификации, но это не внутреннее метапознание, а внешняя помощь. В отчете AISI 2025 года подчеркивается, что масштабирование LLM не решает эту проблему, и для AGI нужны новые архитектуры, интегрирующие оценку «неуверенности», как в байесовских сетях. Без метапознания ИИ остается «чёрным ящиком», где пользователи не могут доверять выводам, что тормозит переход к AGI.

Для оценки прогресса к AGI используются специализированные бенчмарки, фокусирующиеся на абстрактном рассуждении, переносе знаний и обобщении. Один из самых строгих – ARC-AGI, разработанный Франсуа Шолле. Этот тест проверяет способность ИИ распознавать паттерны в визуальных пазлах и применять их к новым задачам, без опоры на предобученные данные. Люди практически безошибочно способны решать эти задачи, но ИИ в свою очередь еле справляются с ними [3].

В ARC-AGI-1 лучшие результаты в 2025 году достигли 79.6% с использованием программных подходов, как в работе Дж. Берман, где эффективность улучшена в 25 раз по сравнению с оз от OpenAI. Однако для ARC-AGI-2, запущенного в 2025 на Kaggle с \$1M призом, лучшие AI-системы показывают всего ~4% успеха, в то время как оз от OpenAI достиг 75.7% на ARC-AGI-1 Public, но проваливается в более сложных задачах ARC-AGI-2, требующих высокоразвитого абстрактного мышления. Список лидеров ARC Prize 2025 подтверждает: даже лучшие решения не приближаются к человеческому уровню, подчеркивая отсутствие абстрактного мышления у современных моделей.

Проблема обучения в реальном времени усугубляет это: модели не адаптируются «на лету» без переобучения, требующего огромных ресурсов. В динамичных окружениях, как например при автономном вождении, это приводит к ошибкам в незнакомых сценариях. Этические аспекты – предвзятость, дезинформация – добавляют сложности: LLM генерируют расистские/сексистские материалы без осознания. Регуляции, как AI Act EC, пытаются исправить эту ситуацию, но технические решения по-прежнему несовершенны. Эти преграды показывают, что современных методов недостаточно для AGI [4].

Подход «снизу вверх» подразумевает создание цифровой модели мозга, начиная с базовых элементов – нейронов, синапсов и нейронных сетей, – и постепенно строя более сложные структуры. В отличие от LLM, которые имитируют поведение через воспроизведение текста на человеческом языке, здесь акцент на биологической точности: моделирование электрических импульсов, химических сигналов и пластичности связей. Это позволяет изучать, как мозг обрабатывает информацию на микроуровне, и потенциально воспроизвести сознание или интеллект.

По сравнению с «сверху вниз» (где LLM обучаются на данных без детального копирования биологии), «снизу вверх» потенциально точнее отражает реальный разум, но требует огромных ресурсов. Например, человеческий мозг содержит около 86 миллиардов нейронов и 100 триллионов синапсов, что делает полную симуляцию вычислительно неподъемной на текущем уровне технологий.

Обзор мнений 22 экспертов в IEEE Spectrum показывает разделение: многие, включая Яна Лекуна и Джейфри Хинтона, скептически относятся к идею, что LLM приведут к AGI, подчеркивая их хрупкость и отсутствие глубокого понимания; Лекун, в частности, отмечает, что LLM ограничены языком и не захватывают сенсорный опыт. Демис Хассабис из DeepMind признает, что LLM – важный шаг, но для AGI нужны новые архитектуры, возможно, вдохновленные мозгом, хотя симуляция мозга тоже не является быстрым решением из-за сложности.

Симуляция мозга, по мнению экспертов, предлагает более фундаментальный подход, но развивается слишком медленно. В отчете The Register отмечается, что AGI остается далекой мечтой, несмотря на бум LLM, и симуляция мозга (neuromorphic computing) может быть альтернативой, но

требует десятилетий на преодоление вычислительных барьеров. Общий консенсус: LLM лидируют в краткосрочной перспективе благодаря скорости развития, но для AGI нужна комбинация – интеграция элементов симуляции мозга в LLM для добавления динамики и биологической верности. В итоге, эксперты вроде Шолле и Маркуса видят AGI в гибридных подходах, а не в чистых LLM или полной симуляции [5].

AGI может стать инструментом процветания, но только если мы подойдем к нему с балансом оптимизма и осторожности, помня, что разум – не цель, а средство для лучшего будущего человечества.

Библиографический список

1. Scaling: The State of Play in AI [Электронный ресурс] // One Useful Thing. – Б. д. – URL: <https://www.oneusefulthing.org/p/scaling-the-state-of-play-in-ai> (дата обращения: 25.10.2025).
2. Smith G. N. Large Language Models: A Lack-of-Progress Report [Электронный ресурс] // Mind Matters. – 2025. – URL: <https://mindmatters.ai/2025/04/large-language-models-a-lack-of-progress-report/> (дата обращения: 25.10.2025).
3. ARC Prize 2025 [Электронный ресурс] // Kaggle. – Б. д. – URL: <https://www.kaggle.com/competitions/arc-prize-2025> (дата обращения: 25.10.2025).
4. Marcus G. Game over. AGI is not imminent, and LLMs are not the royal road to getting there [Электронный ресурс] // Substack. – Б. д. – URL: <https://garymarcus.substack.com/p/the-last-few-months-have-been-devastating> (дата обращения: 25.10.2025).
5. Artificial General Intelligence remains a distant dream despite LLM boom [Электронный ресурс] // The Register. – 2023. – URL: https://www.theregister.com/2023/07/04/agi_llm_distant_dream/ (дата обращения: 25.10.2025).
6. Дашиева, Б. Ш. Статистическая характеристика сельского хозяйства Республики Бурятия и проблема производительности труда: 2006-2012 г.г / Б. Ш. Дашиева // Вестник Бурятской государственной сельскохозяйственной академии им. В.Р. Филиппова. – 2014. – № 3(36). – С. 111-117. – EDN SMSZTH.

УДК 004.67

АНАЛИЗ ЗАРУБЕЖНОГО ОПЫТА СОЗДАНИЯ ИНФОРМАЦИОННОЙ СИСТЕМЫ МОНИТОРИНГА РАЗВИТИЯ БИОЭКОНОМИКИ

Наследов Александр Владиславович, студент 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К.А. Тимирязева, nasledovaleksandr42@gmail.com

Научный руководитель: Дашиева Баярма Шагдаровна, к.э.н., доцент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К.А. Тимирязева, dashieva.b.sh@rgau-msha.ru

Аннотация. В статье проводится анализ информационной системы мониторинга развития биоэкономики Европейского Союза. Составлено описание содержания аналитической системы, обоснована значимость реализации аналогичной информационной системы в Российской Федерации.

Ключевые слова: биоэкономика, мониторинг, информационная система.

ANALYSIS OF INTERNATIONAL EXPERIENCE IN DEVELOPING AN INFORMATION SYSTEM FOR MONITORING BIOECONOMY DEVELOPMENT

Nasledov Aleksandr Vladislavovich, 4th-year student, Institute of Economics and Agribusiness Management, FSAEI HE Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, nasledovaleksandr42@gmail.com

Dashieva Bayarma Shagdarovna, Candidate of Economic Sciences, Associate Professor, Department of Statistics and Cybernetics, FSAEI HE Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, dashieva.b.sh@rgau-msha.ru

Abstract. The article analyzes the European Union's information system for monitoring bioeconomy development. It provides a description of the analytical system's content and substantiates the importance of implementing a similar information system in the Russian Federation.

Keywords: bioeconomy, monitoring, information system.

Биоэкономика – это экономическая модель, направленная на использование возобновляемых биологических ресурсов для производства товаров и услуг, достижение устойчивого развития, минимизацию воздействия на окружающую среду и создание замкнутых экономических циклов [1].

Для эффективного развития биоэкономики необходимо принятие верных и обоснованных решений, что возможно только при наличии достоверных сведений о текущем состоянии развития биоэкономики. Следует отметить, что развитие биоэкономики представляет собой сложное и многокомпонентное явление, характеризующееся разнообразием показателей. Создание информационной системы мониторинга имело бы большую пользу для своевременного принятия правильных решений.

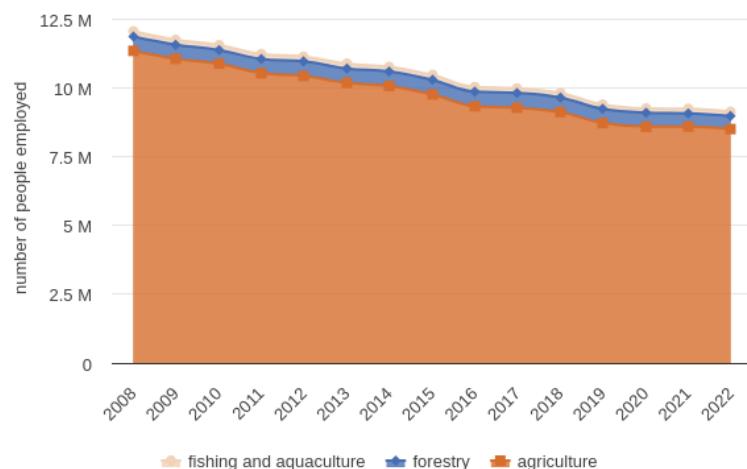
Целью данного исследования является анализ содержания и функциональных особенностей информационной системы мониторинга развития биоэкономики Европейского Союза [3]. Система мониторинга биоэкономики ЕС концептуализируется как интегрированная система, объединяющая «первичное производство», состояние экосистем и «вторичное производство» с акцентом на замкнутые циклы ресурсов и отходов.

Основные показатели разделены на 5 блоков:

1. Первичное производство (производство биомассы, занятость, добавленная стоимость, выбросы, управление).
2. Вторичное производство (использование биомассы, занятость во вторичных секторах экономики, добавленная стоимость от вторичных секторов, выбросы из вторичных секторов, продукты);
3. Отходы и цикличность (пищевые отходы, биологические отходы, цикличность или восстановление);
4. Состояние экосистем (городских, лесных, морских, пресноводных, агроэкосистем);
5. Торговля.

Вся схема показывает, что устойчивость биоэкономики определяется не только состоянием экосистем, но и тем, как организованы торговля, управление отходами и циклы восстановления ресурсов.

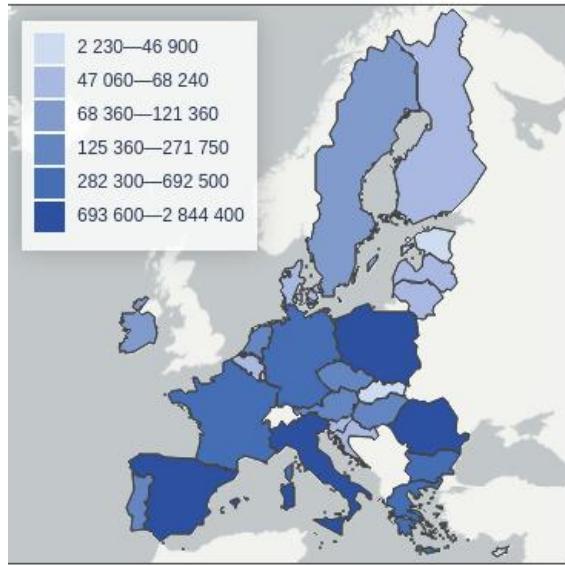
Также внимания заслуживает формат представления данных, например при выборе показателя «Занятость в первичном производстве» строится временной ряд численности занятых в сельском и лесном хозяйстве, рыболовстве (Рисунок 1).



Источник: EU Bioeconomy Monitoring System // European Commission URL:
https://knowledge4policy.ec.europa.eu/bioeconomy/monitoring_en [3].

Рисунок 1 – Численность занятых в сельском и лесном хозяйстве, рыболовстве

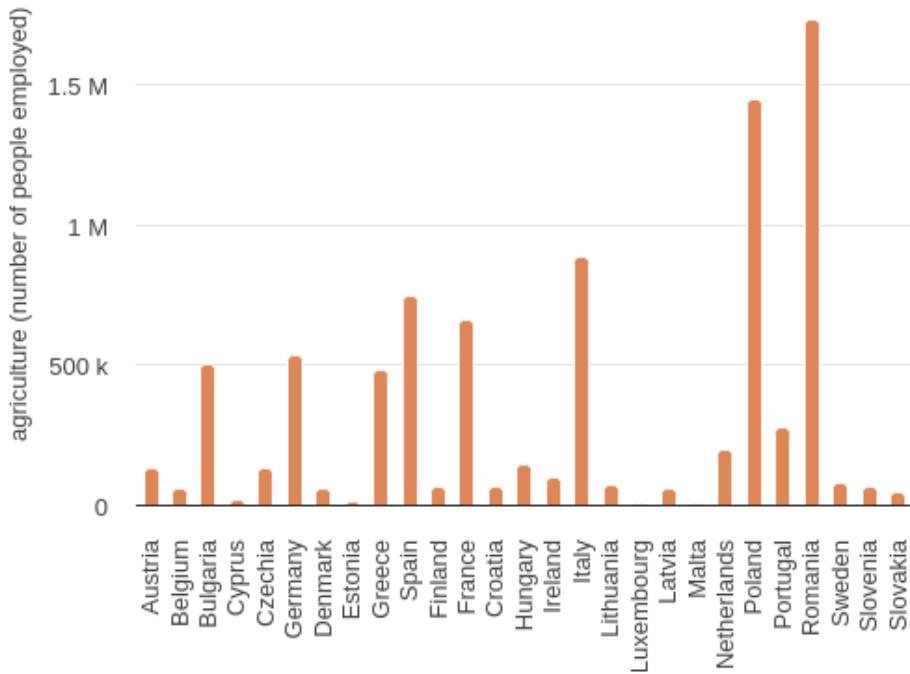
Достаточно информативным может быть построение картограммы (рисунок 2).



Источник: EU Bioeconomy Monitoring System // European Commission URL: https://knowledge4policy.ec.europa.eu/bioeconomy/monitoring_en [3].

Рисунок 2 – Картограмма численности занятых в сельском хозяйстве

Помимо картограммы в данной системе реализовано построение столбчатой диаграммы (рисунок 3).



Источник: EU Bioeconomy Monitoring System // European Commission URL: https://knowledge4policy.ec.europa.eu/bioeconomy/monitoring_en [3].

Рисунок 3 – Столбчатая диаграмма численности занятых в сельском хозяйстве по странам

В настоящее время в России отсутствует система мониторинга развития биоэкономики, а исследования направлены чаще всего на анализ сущности понятия биоэкономики, как в работе [1] или обосновывается значение развития биоэкономики для достижения устойчивого развития [2]. Такие возможности Европейской системы, как построение картограмм и столбчатых диаграмм,

позволят сравнивать показатели развития биоэкономики по регионам РФ, выявлять отстающие и осуществлять меры поддержки данных регионов для гармоничного развития биоэкономики.

Таким образом, учитывая полезность системы мониторинга биоэкономики ЕС, представляется целесообразным адаптировать зарубежный опыт для разработки сопоставимой системы в России. При этом, несмотря на неизбежные различия, обусловленные специфическими природно-ресурсными, институциональными и экономическими условиями России и стран ЕС, базовые принципы и ключевые функциональные элементы данной системы могут быть воспроизведены в национальной системе мониторинга биоэкономики.

Библиографический список

1. Мельник, А. В. Биотехнологии и биоэкономика как основа устойчивого развития в условиях Индустрии 5.0/6.0 / А. В. Мельник, А. В. Бабкин, П. А. Михайлов // Интеллектуальная инженерная экономика и Индустрия 6.0 (ИНПРОМ-2025) : Сборник трудов Международной научно-практической конференции. В 2 т., Санкт-Петербург, 27–30 апреля 2025 года. – Санкт-Петербург: ПОЛИТЕХ-ПРЕСС, 2025. – С. 408-413. – DOI 10.18720/IEP/2025.1/108. – EDN WVONIX.

2. Роднина, Н. В. Биоэкономика как решение вопроса повышения устойчивости сельского хозяйства и продовольственной безопасности / Н. В. Роднина // Региональная экономика. Юг России. – 2025. – Т. 13, № 1. – С. 150-160. – DOI 10.15688/re.volsu.2025.1.15. – EDN CWJSWB.

3. EU Bioeconomy Monitoring System // European Commission URL: https://knowledge4policy.ec.europa.eu/bioeconomy/monitoring_en

УДК 004.896

PANDAS И SCIKIT-LEARN: КАК ПОДГОТОВИТЬ ДАННЫЕ ДЛЯ УСПЕШНОГО ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ

Рыбалкин Богдан Александрович, студент 2 курса института экономики и управления АПК, ФГБОУ ВО РГАУ–МСХА имени К.А. Тимирязева, br3027645@gmail.com

Научный руководитель – Анохин Игорь Александрович, ассистент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ–МСХА имени К.А. Тимирязева, anokhin.igor@rgau-msha.ru

Аннотация. В статье рассматривается предобработка данных для обучения нейронных сетей. Автор рассказывает об основных инструментах

для работы с данными, о разведке и понимании данных, о видах пропущенных значений, о кодировании категориальных признаков и нормализации признаков. Цель работы – рассказать о способах предобработки данных для улучшения качества получаемых моделей при их обучении.

Ключевые слова: большие данные, нейронная сеть, обнаружение аномалий, предобработка данных, машинное обучение, Python, Pandas

PANDAS, AND SCIKIT-LEARN: HOW TO PREPARE DATA FOR SUCCESSFUL NEURAL NETWORK TRAINING

Bogdan Aleksandrovich Rybalkin, 2st year student of the Institute of Economics and Management of Agroindustrial Complex of the Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, br3027645@gmail.com

Scientific supervisor – Anokhin Igor Aleksandrovich, assistant of the Department of Statistics and Cybernetics, of the Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, anokhin.igor@rgau-msha.ru

Annotation. This article discusses data preprocessing for training neural networks. The author discusses key data tools, data exploration and understanding, types of missing values, categorical feature coding, and feature normalization. Particular attention is paid to data preprocessing as a necessary step in training a neural network. The goal of this paper is to describe methods of data preprocessing to improve the quality of the resulting models during their training.

Key words: big data, neural network, anomaly detection, data preprocessing, machine learning, Python, Pandas

Актуальность темы обусловлена тем, что в современном мире, все более часто нейронные сети применяют в различных сферах – от повседневной жизни до принятия стратегических бизнес-решений [1]. В связи с чем качество предлагаемых решений нейронными сетями должно быть максимальным, чего сложно добиться без очищения данных, т.к. это влияет на многие показатели нейронных сетей. Недостаточная очистка данных способна привести к снижению точности модели, её нестабильности из-за чувствительности к выбросам и артефактам, а также к переобучению на шум вместо выявления обобщающих паттернов. Все перечисленное существенно снижает эффективность модели и может повлечь значительные негативные последствия как для бизнеса, так и для конечных пользователей [2].

Является целесообразным акцентировать внимание в работе на инструментах подготовки данных, соответствующие современным стандартам анализа. Основной инструмент (библиотека) для обработки и манипулирования табличными данными является Pandas. Он способен обеспечить эффективную загрузку данных из различных форматов и высокую производительность за счёт написанных на языке С. Так же следует отметить, что ряд иных библиотек используют массивы из Pandas как основой тип данных. Следующая библиотека

Scikit-learn, как раз совместима с массивами Pandas. Scikit-learn используется для предобработки признаков и обучения моделей. Так же для визуализации данных используется библиотека Seaborn. В качестве иллюстративных данных в статье использованы открытые наборы: «Titanic» [5] и «Stack Overflow 2018 Developer Survey» [4].

Первым этапом очистки данных является разведочный анализ, направленный на понимание структуры и характеристик набора данных. Так, загрузка данных в среду анализа осуществляется с использованием функций `pandas.read_csv()` и `pandas.read_excel()` [3], в результате чего формируется объект типа `DataFrame`. Для первичного обзора структуры данных уже применяются методы `info()` и `describe()`: первый предоставляет сведения о типах данных, количестве непропущенных значений и объёме памяти, а второй – основные статистические характеристики числовых признаков (среднее, стандартное отклонение, квантили и др.) [3]. Выявление пропущенных значений выполняется с помощью метода `isnull().sum()` и их визуализация – посредством тепловой карты (heatmap) из библиотеки Seaborn (рис. 1).

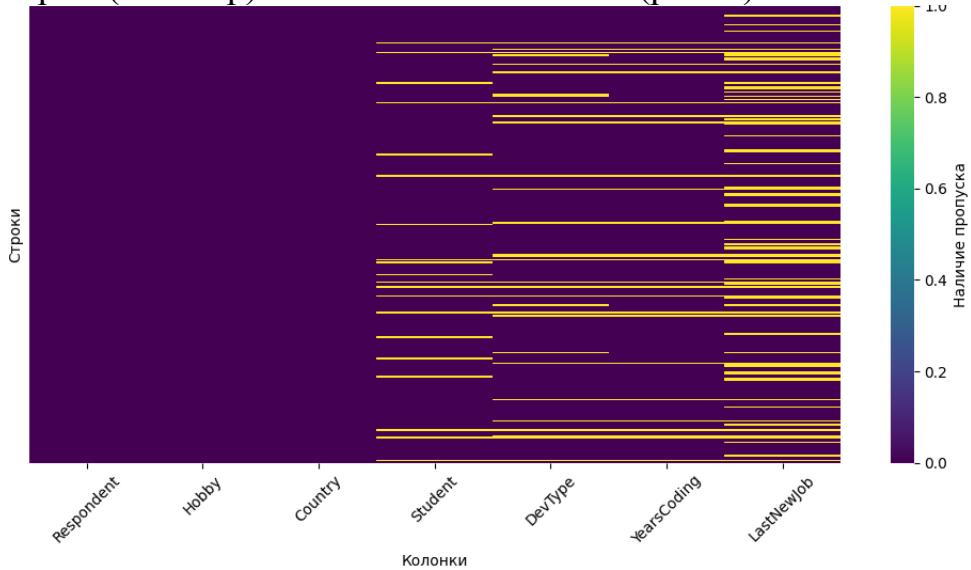


Рисунок 1 – Пример визуализации пропусков

Так же достаточно часто встречающая проблема – это выбросы, их можно удобно отследить через построение scatterplot-а (рис. 2).

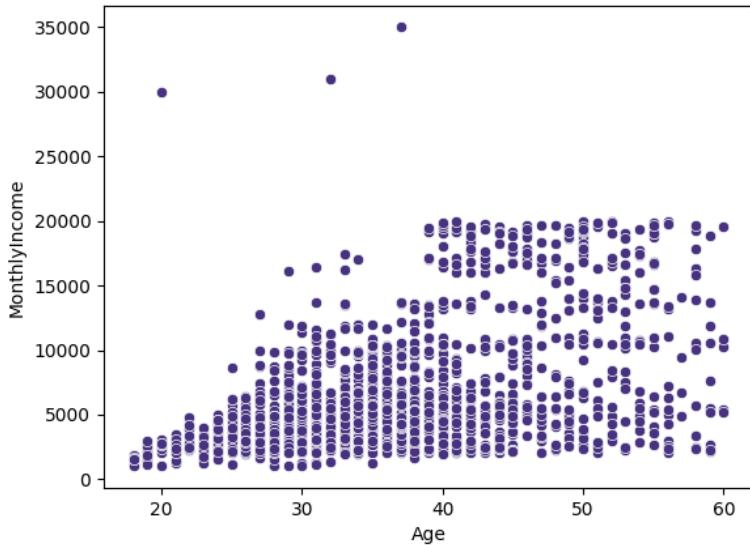


Рисунок 2 – Пример визуализации выбросов

При анализе пропущенных значений выделяют три основных типа:

1) MCAR (Missing Completely At Random) – пропуски полностью случайны и не зависят ни от наблюдаемых, ни от ненаблюдаемых переменных; их удаление не приводит к смещению оценок;

2) MAR (Missing At Random) – вероятность пропуска обусловлена другими наблюдаемыми переменными; такие пропуски допускают коррекцию с помощью методов импутации, однако их удаление может вызвать смещение;

3) MNAR (Missing Not At Random) – пропуски зависят от ненаблюдаемых факторов или от самой пропущенной величины; требуют применения специализированных методов обработки, так как удаление данных в этом случае почти неизбежно ведёт к смещению.

При типе пропусков MCAR и их незначительной доле допустимо удаление строк с помощью метода `dropna()`. В случаях MAR, а также при значительном объёме пропусков даже при MCAR, предпочтительна импутация с использованием метода `fillna()` [3]. При отсутствии выбросов пропущенные значения могут заменяться средним, в противном случае – медианой, как более robustной оценкой центральной тенденции.

Для обработки категориальных признаков, с которыми нейронные сети не могут работать напрямую, применяется кодирование. Номинальные признаки (например, город рождения, департамент), не имеющие естественного порядка, кодируются с помощью one-hot encoding (функции `pd.get_dummies()` или `sklearn.preprocessing.OneHotEncoder`). Порядковые признаки (например, уровень образования), обладающие иерархией значений, преобразуются методами `ordinal` или `label encoding` (например, `sklearn.preprocessing.LabelEncoder`).

Нормализация является ключевым этапом подготовки данных, поскольку признаки, измеренные в различных масштабах (например, возраст и доход), могут необоснованно влиять на обучение модели, затрудняя корректную оценку их значимости. Наиболее распространённые методы нормализации включают: `StandardScaler`, приводящий данные к стандартному нормальному распределению (среднее $\mu \approx 0$, стандартное отклонение $\sigma \approx 1$); `MinMaxScaler`,

масштабирующий значения в диапазон [0, 1]; и RobustScaler, использующий медиану и межквартильный размах, что обеспечивает устойчивость к выбросам.

Таким образом, предобработка данных является обязательным, а не опциональным этапом подготовки к обучению нейронных сетей, поскольку её отсутствие приводит к некорректной работе модели и генерации недостоверных результатов, что может повлечь серьёзные последствия для пользователей. Основные этапы предобработки включают: разведочный анализ данных для оценки их структуры и характеристик; выявление артефактов, пропущенных значений и выбросов (часто с использованием визуализации); обработку пропусков (удаление или импутация) и коррекцию выбросов; кодирование категориальных признаков; а также нормализацию числовых признаков. Совокупность этих процедур обеспечивает корректное представление данных и повышает качество и устойчивость моделей машинного обучения.

Библиографический список

1. Научный форум: Экономика, управление и цифровые технологии в АПК-2024 : Сборник трудов, приуроченных к Международной научно-практической студенческой конференции, Москва, 20 ноября 2024 года. – Москва: Российский государственный аграрный университет, 2024. – 488 с. – ISBN 978-5-9675-2048-8. – EDN CKWNQW.
2. Свидетельство о государственной регистрации программы для ЭВМ № 2024690429 Российской Федерации. «Программное средство для верификации личностей пользователей во время ВКС с использованием методов искусственного интеллекта» : № 2024688865 : заявл. 29.11.2024 : опубл. 16.12.2024 / А. Д. Титов, В. В. Демичев, Д. Э. Храмов [и др.] ; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева». – EDN INWDCO.
3. Pandas documentation. API reference. Version 2.3.3 // pandas.pydata.org. – 2025. – URL: <https://pandas.pydata.org/docs/reference/io.html> (дата обращения: 13.10.2025).
4. Stack Overflow 2018 Developer Survey [Электронный ресурс] // Kaggle. – 2025. – URL: <https://www.kaggle.com/datasets/stackoverflow/stack-overflow-2018-developer-survey> (дата обращения: 13.10.2025).
5. Titanic: Machine Learning from Disaster [Электронный ресурс] // Kaggle. – 2025. – URL: <https://www.kaggle.com/c/titanic/data> (дата обращения: 13.10.2025).
6. Mannapova, R. A. Statistical analysis of the development of beekeeping in the categories of farms / R. A. Mannapova, L. I. Horuzhij, Z. A. Zalilova // European Journal of Natural History. – 2012. – No. 5. – P. 36. – EDN PWFNHR.
7. Уколова, А. В. Статистический и эконометрический анализ трудовых ресурсов регионов США по данным сельскохозяйственных переписей / А. В. Уколова, Б. Ш. Дашиева // Статистика в современном мире: методы, модели, инструменты : Материалы IV Международной научно-практической конференции, Ростов-на-Дону, 27 мая 2016 года. – Ростов-на-Дону: Ростовский

государственный экономический университет "РИНХ", 2016. – С. 82-84. – EDN WQFYWZ.

8. Быков, Д. В. Автоматизация кластерного анализа на основе многомерных средних средствами языка Python по результатам ВСХП-2016 / Д. В. Быков, А. В. Уколова // Электронный сетевой политехнический журнал "Научные труды КубГТУ". – 2023. – № 1. – С. 94-105. – EDN LANAYS.

9. Зинченко, А. П. Региональная и муниципальная статистика : Практикум / А. П. Зинченко, В. В. Демичев. – Москва : Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2016. – 80 с. – EDN XRAUHN.

10. Романова, М. А. Алгоритмы обработки текста / М. А. Романова, Д. Э. Храмов // Материалы международной научно-практической конференции "Тренды развития сельского хозяйства и агрообразования в парадигме Зеленой экономики" : сборник статей, Москва, 14–15 июня 2023 года. – Москва: Российский государственный аграрный университет- Московская сельскохозяйственная академия им. К.А. Тимирязева, 2023. – С. 252-257. – EDN HZDKZR.

УДК: 004.8:631.12

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ ПРОТИВ БОЛЕЗНЕЙ РАСТЕНИЙ: СИЛА НЕЙРОННЫХ СЕТЕЙ RESNET И EFFICIENTNET

Солженицына Мария Сергеевна, студентка I курса института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К.А. Тимирязева, solzhenitsyna.mari@bk.ru

Научный руководитель – Маслакова Веста Владимировна, доцент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К.А. Тимирязева, lenora-@mail.ru

Аннотация. В статье рассматриваются возможности применения современных архитектур свёрточных нейронных сетей – ResNet и EfficientNet – для автоматической диагностики заболеваний растений по изображениям. Автор раскрывает принцип работы нейросетевых моделей, сравнивает их особенности с точки зрения скорости обработки и точности диагностики, а также описывает инструменты, используемые для их обучения (TensorFlow/Keras, PyTorch, Albumentations). Подчёркивается практическая значимость таких технологий для садоводов и фермеров: ускорение выявления болезней, снижение экономических потерь и повышение эффективности агрохода. Статья демонстрирует, как искусственный интеллект становится надёжным помощником в современном растениеводстве.

Ключевые слова: искусственный интеллект, нейронные сети, ResNet, EfficientNet, диагностика болезней растений, компьютерное зрение, сельское хозяйство, машинное обучение, TensorFlow, PyTorch, Albumentations.

ARTIFICIAL INTELLIGENCE AGAINST PLANT DISEASES: THE POWER OF RESNET AND EFFICIENTNET NEURAL NETWORKS

Maria Sergeevna Solzhenitsyna, 1st-year student, Institute of Economics and Management in Agro-Industrial Complex, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), solzhenitsyna.mari@bk.ru

Scientific Supervisor: **Vesta Vladimirovna Maslakova**, Associate Professor, Department of Statistics and Cybernetics, Federal State Budgetary Educational Institution of Higher Education Russian State Agrarian University – Moscow Timiryazev Agricultural Academy (RGAU–MSHA), lenora-@mail.ru

Abstract. This article explores the potential of modern convolutional neural network architectures—ResNet and EfficientNet—for automated plant disease diagnosis from images. The author explains the underlying principles of these models, compares their performance in terms of processing speed and diagnostic accuracy, and describes the tools used for training them (TensorFlow/Keras, PyTorch, Albumentations). The practical value of these technologies for gardeners and farmers is emphasized: faster disease detection, reduced economic losses, and improved agricultural care efficiency. The paper demonstrates how artificial intelligence is becoming a reliable assistant in modern crop cultivation.

Keywords: artificial intelligence, neural networks, ResNet, EfficientNet, plant disease diagnosis, computer vision, agriculture, machine learning, TensorFlow, PyTorch, Albumentations.

Каждый садовод сталкивался с ситуацией, когда, внезапно заметив пятнышко на листочке любимого растения, начинаешь волноваться: «Что случилось?» Обычно приходилось обращаться к специалистам, дожидаясь результата анализов, теряя драгоценное время.

Сегодня на помощь приходят новейшие технологии – нейронные сети. Одна фотография, пара минут ожидания – и готов точный диагноз! Именно таким помощником становятся нейронные сети, способные за секунды сказать, здорово ваше растение или нуждается в лечении.

Работа нейронная сеть похожа на человеческий мозг, только специализированный исключительно на анализе изображений. [1] Ей дают посмотреть тысячи фотографий здоровых и больных растений, она внимательно изучает каждую деталь и формирует понимание, какая картина соответствует здоровой культуре, а какая сигнализирует о заболевании.

Затем, получив новую фотографию, сеть сравнит её с ранее увиденными образцами и скажет своё мнение. Такой способ позволяет быстро выявить проблему и вовремя предпринять меры.

Двумя наиболее популярными типами нейронных сетей является ResNet и EfficientNet. ResNet – эта сеть очень удобна для быстрой проверки состояний растений. Она обладает уникальной способностью глубоко изучать изображения, передавая важные сигналы через всю структуру и формируя чёткий диагноз. EfficientNet – чуть сложнее, но гораздо экономичнее в плане затрат энергии компьютера. Этую сеть выбирают тогда, когда важна максимальная точность диагноза, пусть даже ценой небольшого замедления работы. [2]

Касательно обучения нейронных сетей: чтобы нейронная сеть знала своё дело, её нужно обучить. Представь, что это как подготовка школьника к экзамену: ему показывают тысячи примеров болезней растений, и он их подробно изучает. Потом, увидев новый лист, ученик тут же вспоминает нужный урок и уверенно ставит диагноз. [3]

Обучение осуществляется с помощью специализированных компьютерных программ: TensorFlow/Keras – одни из самых распространённых инструментов для обучения нейросетей; PyTorch – отличная альтернатива первым двум, часто предпочитаемая специалистами за удобство и быстродействие; Albumentations – специальное ПО, которое создаёт вариации исходных изображений, делая обучение разнообразнее и полезнее. [4]

Преимуществом нейронных сетей для садоводов и фермеров является: более быстрое диагностирование болезней растений, экономия времени и денег, предупреждение рисков порчи урожая, повышение эффективности и упрощение ухода за растениями. [5]

Подводя итог, можно смело утверждать: нейронные сети ResNet и EfficientNet уже доказали свою пользу в борьбе с заболеваниями растений. Сейчас их внедрение становится нормой в современном сельском хозяйстве, и в будущем каждый фермер получит надёжного виртуального ассистента, готового прийти на помощь в любое мгновение.

Библиографический список

1. Галеев А.М., Рожков Ю.А. Основы компьютерного зрения и обработки изображений растений // Труды Института прикладной математики и механики РАН. 2021. №24. С. 145-160.
2. Майоров В.Н., Максимов А.О. Эффективность моделей ResNet и EfficientNet в распознании болезней растений // Журнал инновационных технологий в агротехнологиях. 2023. №4. С. 78-89
3. Дмитриченко О.П., Полянская Е.С. Нейронные сети для диагностики заболеваний сельскохозяйственных культур // Научные труды аграриев. 2022. №12. С. 112-124.
4. Сидорчук А.А., Курбатов Ф.А. Программные средства TensorFlow и Keras для разработки приложений по распознаванию болезней растений //

Информационные технологии в аграрном секторе экономики. Саратов: Саратовский государственный аграрный университет, 2022. С. 123-134.

5. Леонов А.Е., Мирошниченко С.Ф. Автоматизация диагностики болезней растений методами машинного обучения // Сборник научных трудов Международной конференции «Наука и инновации в агропромышленном комплексе». СПб.: Политехника-сервис, 2022. С. 234-245.

6. Корреляционно-регрессионный анализ влияния экономических факторов на урожайность пшеницы / В. И. Хоружий, Д. В. Быков, А. В. Уколова, А. Г. Ибрагимов // Бухучет в сельском хозяйстве. – 2024. – № 8. – С. 557-571. – DOI 10.33920/sel-11-2408-04. – EDN MMQTOR.

7. Романцева, Ю. Н. Цифровые решения для расчета углеродного следа в сельском хозяйстве / Ю. Н. Романцева, А. М. Бодур // Экономика и управление: проблемы, решения. – 2024. – Т. 15, № 11(152). – С. 150-159. – DOI 10.36871/ek.up.p.r.2024.11.15.021. – EDN PIBJXJ.

8. Быков, Д. В. Автоматизация кластерного анализа на основе многомерных средних средствами языка Python по результатам ВСХП-2016 / Д. В. Быков, А. В. Уколова // Электронный сетевой политехнический журнал "Научные труды КубГТУ". – 2023. – № 1. – С. 94-105. – EDN LANAYS.

9. Титов, А. Д. Использование нейронных сетей для распознавания образов / А. Д. Титов // Сборник трудов приуроченных к 74-й Всероссийской студенческой научно-практической конференции, посвященной 200-летию со дня рождения П.А.Ильинкова, Москва, 01 января – 31 2021 года. – Москва: Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2021. – С. 50-53. – EDN SIRZRI.

10. Маслакова, В. В. Анализ социально-экологических трансформаций в сельском хозяйстве России / В. В. Маслакова, В. С. Токарев // Бухучет в сельском хозяйстве. – 2024. – № 5. – С. 325-338. – DOI 10.33920/sel-11-2405-03. – EDN QMKXWS.

11. Кагирова, М. В. Расширение сегмента потребителей органической продукции сельского хозяйства с использованием информационных технологий / М. В. Кагирова, Ю. Н. Романцева, С. О. Семенова // International Agricultural Journal. – 2023. – Т. 66, № 4. – DOI 10.55186/25876740_2023_7_4_5. – EDN GOPRME.

УДК 004.83

ПРИМЕНЕНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСПОЗНАВАНИЯ ИЗОБРАЖЕНИЙ С ИСПОЛЬЗОВАНИЕМ PYTHON И TENSORFLOW

Шадыкулов Амин Рустамович, студент 4 курса института экономики и управления АПК, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева,aminshadikylyv20040@mail.ru

Научный руководитель – Титов Артем Денисович, ассистент кафедры статистики и кибернетики, ФГБОУ ВО РГАУ – МСХА имени К. А. Тимирязева

Аннотация. В статье рассматриваются подходы к построению и обучению сверточных нейронных сетей (CNN) для решения задач распознавания изображений. Проанализированы особенности архитектуры CNN, роль библиотек TensorFlow и Keras, а также преимущества языка Python для реализации интеллектуальных систем. Рассмотрены результаты моделирования, подтверждающие эффективность применения нейронных сетей в области компьютерного зрения.

Ключевые слова: нейронные сети, Python, TensorFlow, распознавание изображений, машинное обучение.

APPLICATION OF CONVOLUTIONAL NEURAL NETWORKS FOR IMAGE RECOGNITION USING PYTHON AND TENSORFLOW

Shadykulov Amin, 4th year student, Institute of Economics and Management of Agro-Industrial Complex, Russia State Agrarian University – Moscow Timiryazev Agricultural Academy, aminshadikyli20040@mail.ru

Scientific advisor – Titov Artem, Assistant at the Department of Statistics and Cybernetics, Russia State Agrarian University – Moscow Timiryazev Agricultural Academy, a.titov@rgau-msha.ru

Abstract. The article examines the approaches to designing and training convolutional neural networks (CNNs) for solving image recognition tasks. The architectural features of CNNs, the role of the TensorFlow and Keras libraries, and the advantages of the Python programming language for implementing intelligent systems are analyzed. The results of modeling are discussed, confirming the effectiveness of using neural networks in the field of computer vision.

Keywords: neural networks, Python, TensorFlow, image recognition, machine learning.

За последние годы развитие искусственного интеллекта (ИИ) стало одним из главных направлений цифровой экономики [1, 2]. Технологии, связанные с анализом изображений, активно внедряются в медицину, промышленность, транспорт и даже сельское хозяйство. Ключевым инструментом, обеспечивающим высокую точность таких систем, являются сверточные нейронные сети.

Сверточные сети отличаются тем, что сами «находят» важные особенности в изображении – границы, текстуры, формы – и обучаются на больших массивах данных без ручной разметки признаков.

Именно поэтому они применяются там, где классические методы компьютерного зрения оказываются недостаточными.

Для разработки и обучения модели использовался язык Python и библиотека TensorFlow, которая сегодня считается одной из самых удобных платформ для построения нейронных сетей [3].

Дополнительно применялась Keras – надстройка, упрощающая создание и настройку слоёв сети.

Преимуществом Python является простота синтаксиса и наличие большого числа библиотек для работы с данными и визуализации. В качестве обучающего набора данных использовался открытый набор CIFAR-10, включающий изображения десяти категорий объектов. Перед обучением данные были нормализованы, что позволило повысить стабильность модели и сократить время обучения. Архитектура сети включала несколько сверточных слоёв, слои подвыборки и один полно связанный слой на выходе, который выполнял классификацию изображений по классам. После проведения серии экспериментов модель показала точность распознавания более 90 %. Это хороший результат для сравнительно простой архитектуры, построенной с нуля.

TensorFlow позволил эффективно использовать ресурсы видеокарты, благодаря чему обучение проходило быстро, а библиотека Keras упростила настройку гиперпараметров и визуализацию результатов. Важно отметить, что точность сети напрямую зависит от качества данных. При добавлении новых изображений и увеличении числа эпох обучения результаты стали стабильнее. Методы регуляризации, такие как Dropout, помогли избежать переобучения, сохранив способность модели обобщать информацию [4].

Таким образом, CNN подтвердили свою пригодность для задач, связанных с автоматическим анализом изображений, включая распознавание объектов, сортировку или медицинскую диагностику [5]. Сверточные нейронные сети представляют собой один из самых эффективных инструментов в области анализа изображений. Благодаря сочетанию языка Python и библиотеки TensorFlow разработка таких моделей становится доступной даже студентам и начинающим исследователям. Результаты показали, что CNN обеспечивают высокую точность при сравнительно невысокой вычислительной сложности. В дальнейшем планируется изучить применение предобученных архитектур (VGG, ResNet, MobileNet) и методов Transfer Learning, что позволит сократить время обучения и повысить качество классификации.

Полученные результаты подтверждают, что развитие инструментов машинного обучения на Python способствует распространению технологий искусственного интеллекта в различных сферах деятельности.

Библиографический список

1. Chollet F. Deep Learning with Python. – Manning Publications, 2021.
2. Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press, 2016.
3. TensorFlow Documentation – <https://www.tensorflow.org>
4. LeCun Y., Bottou L., Haffner P. Gradient-based learning applied to document recognition // Proceedings of the IEEE, 1998.

5. Brownlee J. Deep Learning for Computer Vision. – Machine Learning Mastery, 2022.

6. Демичев, В. В. Кластеризация регионов России по уровню эффективности сельского хозяйства / В. В. Демичев, В. В. Маслакова, А. А. Нестратова // Бухучет в сельском хозяйстве. – 2020. – № 12. – С. 58-66. – DOI 10.33920/sel-11-2012-06. – EDN TKTBRZ.

7. Титов, А. Д. Использование нейронных сетей для распознавания образов / А. Д. Титов // Сборник трудов приуроченных к 74-й Всероссийской студенческой научно-практической конференции, посвященной 200-летию со дня рождения П.А.Ильинкова, Москва, 01 января – 31 2021 года. – Москва: Российский государственный аграрный университет - МСХА им. К.А. Тимирязева, 2021. – С. 50-53. – EDN SIRZRI.

Научное издание

МАТЕРИАЛЫ

заседания секции «Нейронные сети на языке Python в АПК» Международной научно-практической конференции «Цифровые компетенции – сельскому хозяйству»

Сборник статей

Издаётся в авторской редакции

Компьютерный набор А.Д. Титов

Подписано к изданию 22.12.2025.

Объём данных 1,93 Мб.

Тираж 10 экз.

ФГБОУ ВО РГАУ – МСХА имени К.А. Тимирязева
127434 Москва, ул. Тимирязевская, 49