

Вредоносное ПО, как Koobface, заражает компьютеры пользователей социальных сетей и создает бот-сети. Фишинговые атаки, например в Facebook (соцсеть признана экстремистской и запрещенной на территории России, заблокирована РКН), обманывают пользователей, заставляя их раскрывать конфиденциальную информацию. Спамеры используют фальшивые профили для распространения рекламы. XSS-атаки, такие как червь Mikeuu, распространяются через уязвимости в соцсетях.

Интернет-мошенники, используя соцсети, получают доверие жертв и крадут их данные. Например, в 2010 году мошенники взломали аккаунт Эбигейл Пикетт в Facebook (соцсеть признана экстремистской и запрещенной на территории России, заблокирована РКН), чтобы выманить деньги у ее друзей.

Современные угрозы часто нацелены на личную информацию пользователей и их друзей. Злоумышленники могут создавать поддельные профили, собирать данные через друзей или использовать атаки вывода для получения конфиденциальных сведений.

Примеры угроз

1. Clickjacking – обман, заставляющий пользователей нажимать не то, что они хотели.

2. Деанонимизация – раскрытие настоящей личности через файлы cookie, группы и топологию сети.

3. Распознавание лица – создание биометрической базы данных из публичных фото.

4. Поддельные профили – автоматизированные аккаунты для сбора личных данных.

5. Атаки клонирования личности – дублирование профиля для обмана друзей и сбора информации.

6. Атаки вывода – анализ общедоступных данных для получения скрытой информации.

7. Утечка локации – обмен данными о местонахождении через соцсети.

8. Socware – вредоносные сообщения и приложения, маскирующиеся под друзей.

Дети, как малые, так и подростки, подвергаются угрозам в социальных сетях, включая онлайн-хищников, рискованное поведение и кибербуллинг.

Онлайн-хищники: Педофилы в интернете могут использовать детей для производства и распространения детской порнографии, а также для онлайн- или офлайн-эксплуатации. Исследования показывают, что контент, контакты с взрослыми и рискованное поведение детей могут привести к серьезным последствиям.

Рисковое поведение: Прямое общение с незнакомцами, интимные разговоры, предоставление личной информации и фотографий – все это увеличивает риск для детей. Комбинация этих действий может быть особенно опасной.

Кибербуллинг: Издевательства в интернете через электронные письма, чаты и соцсе-

ти, включающие публикацию оскорбительных материалов и угроз, особенно сильно влияют на детей. Опрос показал, что 12% родителей сталкивались с кибербуллингом своих детей, чаще всего на платформах вроде Facebook (соцсеть признана экстремистской и запрещенной на территории России, заблокирована РКН).

Радикализация: Террористические организации, такие как ИГИЛ, используют соцсети для вербовки и распространения информации о своих планах. Борьба с такими угрозами требует обнаружения и пресечения распространения вредоносных сообщений.

Заключение

Сообщения в социальных сетях выступают катализатором многообразных угроз: от индивидуального мошенничества до масштабных информационных кампаний. Их объединяет высокий уровень маскировки под легитимный контент.

Ключевые угрозы:

- фишинг и социальная инженерия (поддельные ссылки, имитация доверенных лиц);
- дезинформация (фейки, манипулятивные нарративы);
- кибербуллинг (травля, доксинг);
- утечка данных (скрапинг, анализ цепочек сообщений);
- экстремистская агитация (вербовка, координация незаконных действий).

Список литературы

1. Kotenko I., Vitkova L., Saenko I., Tushkanova O., Branitskiy A. The intelligent system for detection and counteraction of malicious and inappropriate information on the Internet // AI Communication. 2020. Vol. 33. № 1. P. 13-25. DOI: 10.3233/aic-200647.
2. Vitkova L., Kotenko I., Kolomeets M., Tushkanova O., Chechulin A. Hybrid Approach for Bots Detection in Social Networks Based on Topological, Textual and Statistical Features // Proceedings of the Fourth International Scientific Conference Intelligent Information Technologies for Industry. Springer. 2020. Vol. 1156. P. 412-421. DOI: 10.1007/978-3-030-50097-9_42.
3. Liu L., Peng, T. Clustering-based method for positive and unlabeled text categorization enhanced by improved TFIDF // Journal of Information Science and Engineering. 2014. Vol. 30. P. 1463-1481.
4. Li X.L., Liu B., Ng S. K. Negative training data can be harmful to text classification // Proceedings of the 2010 conference on empirical methods in natural language processing. Association for Computational Linguistics. 2010. P. 218-228.

АВТОМАТИЗИРОВАННАЯ СИСТЕМА ИДЕНТИФИКАЦИИ ОБЪЕКТОВ ВОЗДУШНОГО ПРОСТРАНСТВА

Рукас М. К., Букреев Д. А.

ФГБОУ ВО «Мелитопольский государственный университет», Мелитополь,
e-mail: dmitriy.bukreev@mel-su.ru

Научный руководитель: Букреев Д. А.

Введение

Современное воздушное пространство характеризуется высокой динамичностью, ростом плотности воздушного движения и быстрым

распространением беспилотных летательных аппаратов, используемых как в гражданских, так и в потенциально опасных целях. Увеличение числа малозаметных, манёвренных и разнородных объектов существенно усложняет задачи их наблюдения, сопровождения и идентификации. Традиционные методы радиолокационного и оптико-электронного контроля, основанные преимущественно на ручной классификации или пороговой обработке сигналов, оказываются недостаточно эффективными при высокой скорости изменения обстановки и большом объёме информации. Это приводит к росту нагрузки на оператора и повышает риск возникновения ошибок, особенно в условиях помех, недостаточной видимости и неоднородности данных. В этих условиях становится актуальным переход к интеллектуальным автоматизированным системам анализа, использующим методы искусственного интеллекта и машинного обучения. Нейронные сети обладают способностью выявлять сложные взаимосвязи в данных и адаптироваться к изменяющимся условиям наблюдения, что делает их перспективным инструментом для решения задач идентификации воздушных объектов. Применение глубоких сверточных архитектур, детекторов реального времени и гибридных нейросетевых моделей позволяет повысить точность классификации, сократить задержку обработки видеопотоков и снизить влияние человеческого фактора. Такие технологии создают предпосылки для построения комплексных систем мониторинга, способных автоматически распознавать объекты различных типов, прогнозировать их поведение и предоставлять оператору структурированную информацию для принятия решений. Предлагаемый подход обеспечивает адаптацию модели к изменяющимся условиям наблюдения и повышение достоверности идентификации при ограниченных вычислительных ресурсах. Практическая значимость заключается в возможности применения разработанной системы в комплексах контроля воздушного пространства, центрах управления БПЛА, системах видеонаблюдения и учебно-тренировочных платформах.

Цель исследования – автоматизация процесса идентификации объектов воздушного пространства, путем использования методов искусственных нейронных сетей и ориентированной на функционирование в режиме реального времени.

Материалы и методы исследования

Исследование автоматизированной системы идентификации объектов воздушного пространства опирается на совокупность методов анализа данных, машинного обучения и технологий компьютерного зрения, обеспечивающих интеллектуальную обработку визуальной информации в реальном времени. Методологическая

база включает изучение современных подходов к классификации и распознаванию объектов, анализ архитектур глубоких нейронных сетей, а также разработку алгоритмов, обеспечивающих стабильность функционирования системы при изменяющихся условиях наблюдения.

Материалом исследования служат изображения и видеопотоки, полученные от оптических и инфракрасных средств наблюдения. Данные характеризуются высокой вариативностью – различием ракурсов, расстояний, освещённости, погодных условий и степенью контрастности изображений. Для подготовки обучающих выборок используются специализированные наборы данных, включающие изображения самолётов, вертолётов, беспилотных аппаратов, птиц и неидентифицируемых объектов. Для повышения репрезентативности выборки применяется аугментация данных: масштабирование, повороты, отражения, варьирование яркости и контраста. Такой подход позволяет повысить устойчивость модели к внешним искажениям и расширить диапазон условий, при которых сохраняется корректность идентификации.

Результаты исследования и их обсуждение

Архитектура автоматизированной системы идентификации объектов воздушного пространства представляет собой многоуровневую модульную структуру, предназначенную для комплексной обработки визуальных данных в реальном времени. Основная идея заключается в объединении разнородных сенсорных источников, интеллектуальных нейросетевых алгоритмов и управляющих компонентов в единую вычислительную платформу, обеспечивающую высокую скорость анализа, устойчивость к внешним воздействиям и возможность дальнейшего масштабирования [1]. Формирование архитектуры осуществлялось на основе анализа современных систем ситуационной осведомлённости и опыта внедрения нейронных сетей в задачи мониторинга воздушного пространства.

1. Принципы построения архитектуры

При проектировании архитектуры были приняты ключевые системообразующие принципы:

Модульность – каждый компонент отвечает за строго определённую функцию, что обеспечивает взаимозаменяемость и возможность модернизации отдельных модулей без изменения всей системы. Модульная структура позволяет использовать различные модели детекции, алгоритмы классификации или форматы данных, адаптируя подсистему под конкретные условия наблюдения.

Потоковая обработка данных – система функционирует в режиме непрерывного анализа видеопотока, что требует асинхронного выполнения задач: предобработка кадров, детекция,

классификация и фильтрация происходят параллельно. Такое решение минимизирует задержки и обеспечивает работу в реальном времени – одно из ключевых требований для задач контроля воздушного пространства.

Параллелизм вычислений – использование графических ускорителей (GPU) и оптимизированных библиотек глубокого обучения позволяет выполнять детекцию и классификацию одновременно для нескольких объектов и кадров. Это особенно важно при высокой плотности воздушной обстановки, когда в поле зрения находится несколько целей.

Адаптивность – система должна корректно работать при изменении условий освещённости, появлении шумов, изменении ракурса наблюдения и параметров видеопотока. Для этого в архитектуре предусмотрены механизмы дообучения модели, корректировки параметров фильтрации и обновления конвейера обработки данных.

Интегрируемость – архитектура предусматривает возможность подключения к существующим системам радиотехнического и оптико-электронного наблюдения, что расширяет потенциальные области применения – от гражданского контроля до задач ПВО.

Все принципы реализованы в общей структурной схеме, включающей пять функциональных подсистем:

1) Подсистема сбора и первичной обработки данных – отвечает за получение изображений и видеопотоков от оптических, инфракрасных и при необходимости радиолокационных средств наблюдения [5]. На данном уровне выполняются:

- захват и синхронизация кадров;
- нормализация форматов изображения (RGB → Grayscale);
- пространственная стабилизация и подавление шумов;
- коррекция яркости и контраста при отсутствии стабильных условий наблюдения.

2) Подсистема детекции объектов – выделение областей интереса (ROI) в каждом кадре. В системе применяется одношаговая архитектура YOLO (You Only Look Once), позволяющая анализировать изображение целиком, без предварительного выделения регионов вручную.

Преимущества использования YOLO:

- высокая скорость обработки (до 50–60 FPS в оптимизированных конфигурациях);
- устойчивость при работе с объектами различных размеров;
- способность корректно распознавать динамичные цели.

Модель выдаёт координаты рамок и вероятности наличия объектов. Эти данные затем передаются в классификатор, что формирует связанный алгоритмический поток. YOLO выступает первым интеллектуальным фильтром

и существенно снижает нагрузку на дальнейшие этапы обработки.

3) Подсистема идентификации и классификации объектов – является ядром всей архитектуры и содержит глубокую сверточную нейросеть, выполняющую непосредственную идентификацию воздушных объектов [6]. В качестве основной архитектуры используется модификация ResNet-50 и EfficientNet, выбранные благодаря:

- высокой точности классификации;
- устойчивости к искажениям изображения;
- умеренным вычислительным требованиям;
- способности к дообучению и fine-tuning.

На вход классификатора поступают вырезанные фрагменты (ROI), выделенные подсистемой детекции. Нейросеть формирует вероятностное распределение классов: «самолёт», «вертолёт», «БПЛА», «птица», «неопознанный объект». При обработке сложных сцен может применяться ансамблевый подход – например, комбинация CNN и Vision Transformer. Это увеличивает надёжность идентификации при низкой контрастности или частичном перекрытии цели [3].

4) Подсистема принятия решения и фильтрации – результаты нейросетевой классификации проходят дополнительную проверку для исключения ложных срабатываний. Механизм принятия решения включает:

- пороговую фильтрацию по вероятности;
- анализ динамики движения объекта;
- временную корреляцию последовательности кадров;
- проверку согласованности поведения цели.

Для временной коррекции используется рекуррентная нейросеть, анализирующая изменение положения объекта в соседних кадрах. Это особенно важно, когда объект частично перекрыт, быстро меняет траекторию или присутствуют атмосферные артефакты. Модуль принятия решения формирует окончательную метку класса и передаёт данные в подсистему визуализации.

5) Подсистема визуализации, хранения и управления – обеспечивает пользовательский интерфейс и контроль работы всей системы. Основные функции:

- отображение видеопотока с выделенными объектами и вероятностями;
- ведение журнала событий с временными метками и координатами;
- сохранение результатов в базе данных;
- передача данных в внешние системы мониторинга;
- режим ручной верификации оператором.

Хранение данных обеспечивает возможность анализа эффективности, построения статистических моделей и последующего дообучения нейросетей, что является важным элементом адаптивной архитектуры.

Модульность архитектуры позволяет расширять функциональность без изменения ба-

зового контура системы, что делает решение технологически перспективным и готовым к интеграции в реальные комплексы мониторинга воздушного пространства.

2. Алгоритмическое обеспечение и нейросетевая модель

Алгоритмическое обеспечение разработанной системы идентификации формирует её интеллектуальное ядро и определяет характер взаимодействия всех функциональных модулей – от обработки исходных данных до формирования финального решения. В отличие от традиционных алгоритмов, основанных на пороговой фильтрации или ручном выделении признаков, предложенное решение опирается на принципы глубокого обучения, что позволяет значительно расширить возможности системы при работе в условиях неопределённости, помех и высокой динамики воздушной обстановки [4]. Такой подход обеспечивает переход от жёстко заданных правил к адаптивной модели поведения, способной корректировать свои решения в зависимости от текущих условий наблюдения.

Центральным элементом алгоритмической части является последовательный конвейер обработки данных. Он включает несколько взаимосвязанных этапов, каждый из которых вносит собственный вклад в повышение достоверности идентификации. Потокоевое функционирование позволяет системе работать практически без задержек, что особенно важно для видеонаблюдения, где информация быстро устаревает.

Первичная обработка видеопотока направлена на обеспечение стабильности входных данных. Изображения, получаемые от камеры или тепловизора, могут отличаться по яркости, резкости, наличию шумов, а при работе на открытой местности – также по степени воздействия атмосферных факторов. Поэтому на этом этапе выполняются операции нормализации, мягкого шумоподавления и коррекции контрастности. Они не только улучшают визуальные характеристики кадра, но и создают благоприятные условия для корректной работы нейросетевых моделей, чувствительных к нарушениям структуры изображения.

Для решения задачи детекции объектов применяется детектор YOLO, который эффективно совмещает высокую скорость обработки с устойчивой локализацией объектов различных размеров [2]. YOLO анализирует изображение целиком, не разделяя его на отдельные области вручную, что сокращает время обработки и повышает согласованность результатов при работе с динамичными сценами. Детектор формирует набор областей интереса, передаваемых далее на классификацию.

Процедура классификации является центральным моментом всей системы, поскольку именно здесь принимается решение о том,

к какому типу относится наблюдаемый объект [8]. Для решения этой задачи была выбрана глубокая сверточная нейронная сеть ResNet-50, отличающаяся высокой устойчивостью к искажениям и способностью выделять сложные пространственные признаки даже в условиях низкой контрастности или частичного перекрытия объекта. Наличие остаточных связей позволяет модели сохранять качество обучения при значительной глубине, а использование предобученных весов ускоряет адаптацию сети под специфику воздушных объектов. В ряде сценариев классификация дополняется использованием архитектур EfficientNet или Vision Transformer, что обеспечивает повышение устойчивости модели в сложных визуальных условиях.

Ключевым фактором успешного функционирования нейросетевой части является качество обучающей выборки. Для её формирования использовались изображения воздушных объектов различного типа, полученные при разных условиях освещения и на разных расстояниях. Чтобы повысить способность модели к обобщению, применялись методы аугментации – масштабирование, изменение яркости, повороты и добавление шумов. Это позволило имитировать реальные изменения условий наблюдения и обеспечить высокую устойчивость модели к непредвиденным ситуациям.

Финальный этап алгоритма связан с анализом и интерпретацией результатов классификации. Даже самые точные модели глубокого обучения склонны давать колебания на отдельных кадрах, особенно если объект движется быстро, частично перекрыт или находится в зоне низкой видимости [7]. Поэтому система использует дополнительный механизм фильтрации, основанный на проверке временной стабильности и согласованности движения. Если модель фиксирует объект в нескольких соседних кадрах с высокой вероятностью, система подтверждает идентификацию. В противном случае результат подвергается повторной проверке или передаётся на анализ оператору. Такой подход позволяет существенно снизить число ложных тревог, сохраняя при этом способность системы реагировать на реальные угрозы.

3. Тестирование и оценка эффективности функционирования системы

Оценка работоспособности разработанной системы является важнейшим этапом исследования, поскольку именно она позволяет определить, насколько успешно реализованные алгоритмы справляются с задачами детекции и идентификации в условиях, близких к реальной эксплуатации.

Тестирование проводилось на вычислительной платформе, оснащённой графическим ускорителем NVIDIA RTX 3060, что обеспечило необходимую вычислительную мощность

для работы глубоких нейросетевых моделей. В качестве входных данных использовались изображения и короткие видеосегменты, содержащие примеры различных объектов воздушного пространства – самолётов, вертолётов, беспилотных летательных аппаратов, а также птиц и атмосферных объектов, способных вызывать ложные срабатывания. Такая выборка позволила оценить способность системы различать визуально сходные объекты и обрабатывать сцены различной сложности. Всего в тестировании было задействовано около 6000 изображений и 800 видеоклипов, отражающих широкий диапазон условий наблюдения.

Особое внимание уделялось вариативности входных данных: они отличались по разрешению, уровню контрастности, освещённости и степени зашумлённости. Это позволило имитировать реальные условия эксплуатации, где наблюдение может вестись как в дневное, так и в сумеречное время, при наличии тумана, облачности или отражений от наземных объектов.

Одним из ключевых требований к системе является способность функционировать в реальном времени, поскольку задержка при идентификации даже в несколько секунд может привести к потере актуальности данных. Проведённые испытания показали, что система демонстрирует устойчивую скорость обработки видеопотока – в среднем 27–30 кадров в секунду при разрешении 1280×720. Этот показатель остаётся стабильным даже при наличии нескольких объектов в кадре, благодаря разумному распределению нагрузки между детектором и классификатором. Средняя задержка между поступлением кадра и выдачей результата не превышала 140 мс.

Помимо скорости обработки оценивалась устойчивость функционирования системы при изменении условий наблюдения. Даже при существенном ухудшении освещённости или появлении атмосферных искажений система продолжала корректно выделять объекты, а снижение точности оставалось в пределах 5–6 %. Это говорит о том, что выбранные методы предобработки и архитектуры нейронных сетей обладают достаточной адаптивностью.

Ключевыми метриками качества работы системы стали accuracy, precision, recall и F1-score, позволяющие комплексно оценить способность модели правильно классифицировать объекты и избегать ложных срабатываний. По результатам тестирования средняя точность классификации составила 94,7 %, что является высоким показателем, учитывая сложность входных данных и большое количество классов. Метрики precision и recall составили 93,1 % и 92,4 % соответственно, что свидетельствует о сбалансированности модели: она не только правильно идентифицирует большинство объектов, но и практически не пропускает реальные

цели. Система демонстрирует устойчивое поведение при анализе динамичных сцен: последовательная фильтрация на основе временной корреляции позволяет нивелировать случайные ошибки классификации, особенно при появлении быстро перемещающихся или частично перекрытых объектов. Уровень ложных срабатываний не превышал 4,1 %, что является приемлемым значением для задач мониторинга, где ошибочная классификация должна быть сведена к минимуму.

Заключение

Проведённое исследование позволило всесторонне рассмотреть проблему автоматизированной идентификации объектов воздушного пространства и разработать функционально завершённую систему, способную решать задачи мониторинга в условиях реальной эксплуатации. В ходе исследования была сформирована архитектура системы, объединяющая принципы модульности, потоковой обработки данных и адаптивности. Такое построение обеспечивает её гибкость, возможность расширения и интеграции с существующими средствами наблюдения. Нейросетевые модули, основанные на современных архитектурах глубокого обучения, продемонстрировали высокую эффективность при обработке визуальной информации, позволяя уверенно выделять и классифицировать воздушные объекты различной природы. Особое внимание было уделено разработке алгоритмического обеспечения. Использование сочетания детектора YOLO и классификационных моделей типа ResNet обеспечило устойчивое распознавание объектов даже в условиях недостаточной освещённости, шумов или частичного перекрытия цели. Система продемонстрировала способность функционировать в режиме реального времени, а реализованные методы временной фильтрации позволили снизить количество ложных срабатываний и повысить обоснованность принимаемых решений. Проведённые испытания подтвердили работоспособность и надёжность системы. Средняя частота обработки видеопотока достигала 27–30 кадров в секунду, что соответствует требованиям к оперативным системам наблюдения. Точность классификации превысила 94 %, а устойчивость к изменениям внешних условий показала, что системы на основе глубокого обучения могут эффективно использоваться для задач воздушного мониторинга. Сравнение с существующими решениями показало явные преимущества разработанной системы по точности, скорости обработки и уровню ложных срабатываний. Таким образом, разработанная автоматизированная система идентификации объектов воздушного пространства сочетает в себе современные методы искусственного интеллекта, эффективную архитектуру и практическую ориентированность.

Список литературы

1. Андреев К. С. Компьютерное зрение и машинное обучение. СПб.: Питер, 2020.
2. Букреев Д. А., Гуров А. С. Метод распознавания нарушений правил дорожного движения в режиме реального времени с помощью технологий компьютерного зрения // Университетская наука. 2025. № 1(19). С. 168-173.
3. Гонсалес Р., Вудс Р. Цифровая обработка изображений. М.: Техносфера, 2018.
4. Касаткин А. С. Нейросетевые технологии обработки изображений. СПб.: Питер, 2022.
5. Половников Е. П. Технологии машинного обучения в автоматизированных системах. М.: Академия, 2021.
6. Ткачёв Е. В. Применение нейросетевых технологий в радиолокационных системах. М.: Радиотехника, 2022.
7. Bukreiev D. O. et al. Features of the use of software and hardware of the educational process in the conditions of blended learning // AET 2020-Symposium on Advances in Educational Technology // Technology (AET 2020). SCITEPRESS. 2022. №. 2. С. 236-244.
8. Bukreiev D. Neuro-network technologies as a mean for creating individualization conditions for students learning // SHS Web of Conferences. – EDP Sciences. 2020. Т. 75. С. 04013.

**СОВРЕМЕННОЕ СОСТОЯНИЕ
РАЗВИТИЯ ТЕХНОЛОГИЙ
ПРОГНОЗИРОВАНИЯ
ФИНАНСОВЫХ ОПЕРАЦИЙ**

Соболева И. Р., Букреев Д. А.

*ФГБОУ ВО «Мелитопольский государственный университет», Мелитополь,
e-mail: dmitriy.bukreev@mel-su.ru*

Научный руководитель: Букреев Д. А.

Введение

Прогнозирование финансовых операций занимает одно из ключевых мест в современных финансово-экономических системах, поскольку от точности и надёжности прогнозов напрямую зависят эффективность управления рисками, устойчивость финансовых организаций и обоснованность принимаемых управленческих решений. Развитие цифровых технологий, рост объёмов доступных данных и усложнение финансовых инструментов существенно трансформировали подходы к анализу и прогнозированию финансовых процессов, выдвинув на первый план интеллектуальные методы обработки информации. Финансовые операции характеризуются высокой динамичностью, стохастической природой и значительной зависимостью от внешних факторов, включая макроэкономические показатели, поведение участников рынка и глобальные экономические события. Эти особенности существенно усложняют задачу прогнозирования и ограничивают применимость традиционных статистических методов, ориентированных преимущественно на линейные зависимости и стационарные временные ряды. В условиях высокой волатильности и структурных изменений финансовых рынков такие подходы часто оказываются недостаточно устойчивыми и чувствительными к изменению входных

данных. Современное развитие технологий прогнозирования финансовых операций связано с активным внедрением методов машинного обучения и нейросетевых архитектур, способных учитывать нелинейные зависимости, взаимодействие большого числа факторов и скрытые закономерности в данных. Использование интеллектуальных моделей позволяет повысить точность прогнозов и расширить спектр решаемых задач – от краткосрочного прогнозирования транзакционной активности до анализа долгосрочных тенденций финансовых потоков. Вместе с тем применение таких методов сопровождается рядом проблем, связанных с интерпретируемостью моделей, качеством исходных данных и вычислительной сложностью алгоритмов.

Цель исследования – анализ современного состояния развития технологий прогнозирования финансовых операций и выявление основных направлений их эволюции.

Материалы и методы исследования

Материалом исследования послужили научные публикации, аналитические отчёты и результаты прикладных исследований, посвящённых прогнозированию финансовых операций. В рамках исследования учитывались как классические подходы к прогнозированию финансовых временных рядов, так и современные технологии, основанные на методах машинного обучения и нейросетевых архитектурах.

Информационную базу исследования составили теоретические и прикладные источники, отражающие эволюцию методов прогнозирования финансовых операций, включая статистические модели, регрессионные подходы, ансамблевые методы и глубокие нейронные сети. Особое внимание уделялось работам, анализирующим практическую применимость интеллектуальных моделей в условиях реальных финансовых рынков, а также ограничения, возникающие при их использовании.

Методологическая основа исследования включает совокупность аналитических методов, ориентированных на систематизацию и обобщение существующих подходов. В качестве базового применялся теоретико-аналитический метод, позволивший рассмотреть развитие технологий прогнозирования финансовых операций в динамике и выявить ключевые этапы перехода от традиционных методов к интеллектуальным моделям. Такой подход обеспечил целостное представление о современном состоянии данной области.

Для выявления особенностей и ограничений различных технологий использовался сравнительный анализ, направленный на сопоставление классических статистических методов и современных алгоритмов машинного обучения по критериям точности прогнозов, устойчивости к шумам, интерпретируемости результатов и вычислительной сложности. Это