

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение
высшего образования

**«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ИМЕНИ Н. Г. ЧЕРНЫШЕВСКОГО»**

Кафедра информатики и программирования

**ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА АНАЛИЗА
МРТ-ИЗОБРАЖЕНИЙ**

АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ

студента 2 курса 273 группы
направления 02.04.03 — Математическое обеспечение и администрирование
информационных систем
факультета КНиИТ
Калантарова Артема Наилевича

Научный руководитель
профессор, д. ф.-м. н.

П. В. Купцов

Заведующий кафедрой
доцент, к. ф.-м. н.

М. В. Огнева

Саратов 2026

ВВЕДЕНИЕ

Магнитно-резонансная томография (МРТ) является методом визуализации головного мозга, широко применяемым для выявления новообразований. Глубокие сверточные нейронные сети позволяют автоматически выделять информативные признаки на МРТ и достигать высокой точности в задачах сегментации и классификации патологий. Современные архитектуры для семантической сегментации, например, U-Net, Feature Pyramid Network (FPN) или DeepLab, используют пропускные связи для сохранения пространственных деталей, в то время как алгоритмы «You Only Look Once» (YOLO) обеспечивают высокую скорость обнаружения аномалий в режиме реального времени. Дополнительным направлением исследований является повышение интерпретируемости моделей через механизмы внимания и методы визуализации, такие как Gradient-weighted Class Activation Mapping (Grad-CAM), что повышает доверие специалистов к системам искусственного интеллекта. Однако существующие интеллектуальные платформы анализа медицинских изображений часто демонстрируют зависимость точности от качества исходных данных, не обладают механизмами адаптации к новым условиям (демография пациентов, особенности оборудования) и требуют обязательной врачебной верификации без возможности учета экспертных коррекций для последующего улучшения моделей. Это определяет актуальность разработки системы, способной к инкрементальному обучению на потоке клинических данных и обеспечивающей прозрачность принимаемых решений.

Цель работы — разработать интеллектуальную систему автоматического анализа МРТ-изображений для выявления патологий, основанную на методах машинного обучения и технологиях интерпретируемого искусственного интеллекта и предусматривающую возможность дообучения на основе индивидуального опыта практикующего врача. Для достижения поставленной цели сформулированы следующие основные задачи:

1. Проведение обзора существующих решений, обучение нейросетевых моделей для обнаружения патологий, а также их сравнительный анализ.
2. Создание архитектуры системы с конвейером инкрементального обучения для адаптации моделей к новым данным.
3. Внедрение инструментов редактирования разметки, аналитических панелей для визуализации метрик и комплексное тестирование.

В качестве материалов исследования использован набор данных, происходящий из архива The Cancer Imaging Archive (TCIA) в рамках проекта The Cancer Genome Atlas (TCGA) по глиомам низкой степени злокачественности. Набор данных включает 110 пациентов и срезы МРТ в последовательности FLAIR, каждый из которых сопровождается бинарной маской с ручной разметкой областей опухолевой инфильтрации, прошедшей многоэтапную валидацию с участием сертифицированного нейрорадиолога. Все изображения представлены в аксиальной плоскости съемки.

Структура выпускной квалификационной работы определена поставленными задачами и состоит из введения, четырех глав, заключения, списка литературы и приложений. Первая глава «Обзор интеллектуальных систем в здравоохранении» содержит анализ источников медицинских данных, классификацию методов их анализа, обзор существующих коммерческих платформ и систем инкрементального обучения. Вторая глава «Обучение и анализ моделей» посвящена описанию набора данных, процессу обучения и сравнительному анализу моделей семантической сегментации, интерпретации прогнозов методом Grad-CAM, а также обучению и сравнению моделей семейства YOLO для задач обнаружения объектов и сегментации экземпляров. Третья глава «Разработка системы дообучения моделей» описывает проектирование микросервисной архитектуры, включая модули данных, обучения и оценки, а также инфраструктуру программного комплекса. Четвертая глава «Графический интерфейс диагностического комплекса» демонстрирует реализацию интерфейсов для управления пользователями, диагностики, редактирования предсказаний, конфигурации дообучения и аналитической платформы. Дополнительно описывает систему мониторинга метрик работы приложения в реальном времени с использованием интерактивных панелей.

Научная новизна работы заключается в комплексном подходе к созданию адаптивной интеллектуальной системы анализа МРТ-изображений, сочетающем инкрементальное обучение моделей на потоке экспертных коррекций с механизмами интерпретируемости решений. В отличие от существующих платформ, которые демонстрируют зависимость точности от источника данных и не адаптируются к новым условиям, разработанная система внедряет конвейер осторожного обновления весов с балансировкой обучающих выборок, стратегическим замораживанием слоев и регуляризацией.

ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

Первая глава посвящена обзору интеллектуальных систем в здравоохранении, источникам медицинских данных, методам их анализа, существующим коммерческим платформам и подходам к инкрементальному обучению. В первом разделе главы рассматриваются основные источники медицинских данных, используемые в современных системах искусственного интеллекта. Магнитно-резонансная томография обеспечивает трехмерную визуализацию мягких тканей с высоким разрешением. Различные импульсные последовательности предоставляют информацию об анатомических структурах, патологических очагах, отеках, клеточной плотности и микрокровоизлияниях. Рентгенография и компьютерная томография применяются для выявления патологий костных структур и легких. Электрофизиологические методы, например, электрокардиография, электроэнцефалография и холтеровское мониторирование, фиксируют динамические функциональные показатели в реальном времени и служат основой для диагностики аритмий, оценки нейронной активности и морфологии сердечных сигналов. Пульсоксиметрия позволяет неинвазивно измерять сатурацию крови и частоту сердечных сокращений, что актуально для предиктивной диагностики.

Второй раздел содержит анализ методов обработки медицинских изображений. Традиционный ручной анализ врачом-радиологом ограничен субъективностью, когнитивной нагрузкой и риском перцептивных ошибок (до 30% при ретроспективном анализе). Классические компьютерные системы САД, основанные на детерминированных алгоритмах (пороговая сегментация, выделение границ), снижают субъективность, но обладают низкой специфичностью и чувствительностью к шуму. Методы глубокого обучения автоматически извлекают иерархические признаки и превосходят классические алгоритмы по точности, однако остаются «черным ящиком» и требуют больших объемов размеченных данных. Перспективным направлением является адаптивный искусственный интеллект, сочетающий объяснимость и возможность непрерывного обучения на новых данных без забывания.

Третий раздел посвящен обзору существующих интеллектуальных платформ, внедренных в клиническую практику. Несмотря на широкое распространение, данные системы имеют ограничения: зависимость точности от качества снимков и типа оборудования, отсутствие адаптации к новым данным,

необходимость обязательной врачебной верификации, недостаточная интерпретируемость решений. В соответствии с таблицей 1 приведено сравнение недостатков текущих платформ и преимуществ разрабатываемой системы, которая предусматривает инкрементальное обучение, режим совместной работы с коррекцией предсказаний и визуализацию областей интереса методами объяснимого искусственного интеллекта (ИИ):

Таблица 1 – Сравнение текущих платформ и разрабатываемой системы

Существующие платформы	Разрабатываемая система
Зависимость точности от качества и источника данных (протоколы сканирования, оборудование).	Внедрение инкрементального обучения для адаптации модели к новым данным с контролем забывания.
Риск автоматизации предвзятости и необходимость обязательной верификации врачом.	Режим совместной работы с функцией коррекции предварительной сегментации экспертом.
Отсутствие прозрачности и интерпретируемости принятия решений моделью.	Интеграция механизмов объяснимого ИИ, например Grad-CAM, для визуализации областей интереса.

Четвертый раздел рассматривает принципы инкрементального обучения, необходимые для адаптации моделей к потоку экспертных исправлений. Прямое дообучение на новых данных приводит к катастрофическому забыванию ранее усвоенных знаний. Для противодействия этому эффекту предложена методология «осторожного» обновления, включающая использование пониженной скорости обучения, балансировку обучающих мини-выборок смешиванием новых и репрезентативных исходных данных, регуляризацию с помощью Elastic Weight Consolidation (EWC), который штрафует изменение наиболее важных параметров, оценивая их значимость через диагональ матрицы Фишера. Дополнительно применяется стратегическое замораживание начальных слоев сети, сохраняющее универсальные визуальные признаки, и метод повторения с буфером памяти, содержащим 1–5% исходных данных.

Система непрерывного мониторинга метрик на тестовом наборе позволяет выявлять деградацию качества и при необходимости выполнять откат модели. Взаимосвязь компонентов системы дообучения схематично продемонстрирована в соответствии с рисунком 1:

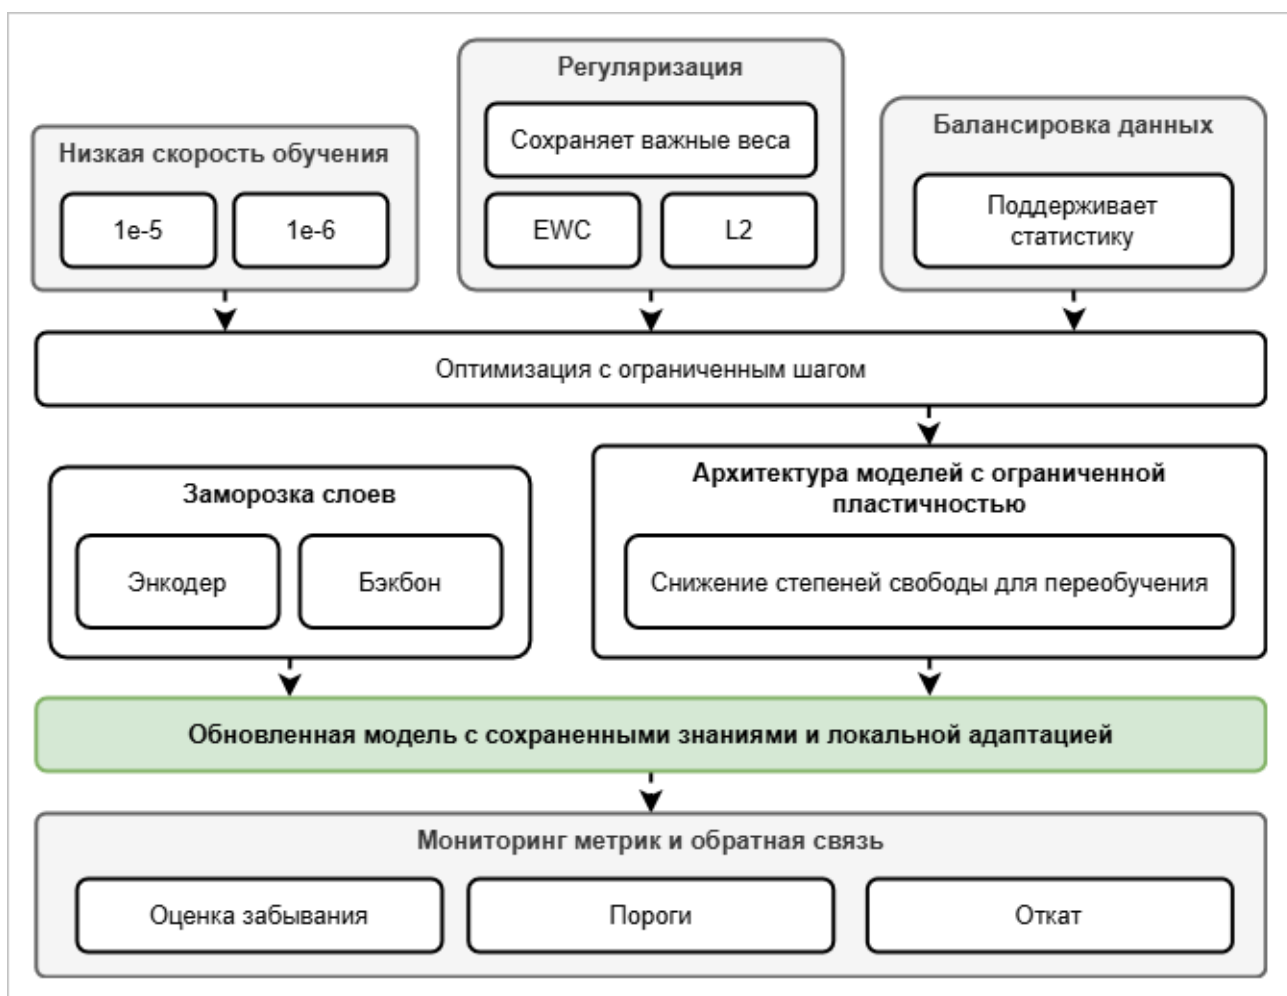


Рисунок 1 – Взаимосвязь компонентов системы дообучения

Во второй главе представлены результаты экспериментального обучения и сравнительного анализа моделей для семантической сегментации, обнаружения объектов и сегментации экземпляров на МРТ-изображениях головного мозга. В первом разделе главы описывается набор данных, использованный в исследовании. На основе данного набора решались три задачи: семантическая сегментация опухолевой ткани с последующей визуализацией областей интереса, сегментация экземпляров новообразований и детекция патологических областей с использованием архитектур семейства YOLO.

Во втором и третьем разделах рассматриваются модели семантической сегментации. Процесс предварительной обработки включал нормализацию интенсивности пикселей, аугментацию данных и разделение выборки на обучающую, валидационную и тестовую части. Для оценки качества применялись метрики Intersection over Union (IoU) и коэффициент Dice, а в качестве функции потерь использовалась Dice loss. Были обучены и протестированы

архитектуры U-Net, FPN, DeepLabV3+, а также их гибридные версии с энкодерами EfficientNet. Для интерпретации решений моделей применялся метод Grad-CAM, визуализирующий области изображения, наиболее значимые для принятия решения. Наилучший результат по коэффициенту Dice показала архитектура FPN, а максимальное значение средней полноты объединения достигнуто гибридной моделью U-Net с энкодером EfficientNet-B7. Сводные результаты семантической сегментации представлены на таблице 2:

Таблица 2 – Ключевые метрики моделей семантической сегментации

Наименование модели	Эпох	Dice	Mean IoU	Dice loss
U-Net	100	0.9047	0.8938	0.0952
FPN	100	0.913	0.9002	0.0868
DeepLabV3+	100	0.9045	0.8633	0.0953
U-Net + EfficientNet-B7	100	0.9086	0.9132	0.0912
U-Net + EfficientNetV2	75	0.9035	0.9084	0.0962
FPN + EfficientNet-B7	100	0.8204	0.803	0.1792
EfficientNet-B7 + DeepLabV3+	100	0.7016	0.6527	0.2973

В четвертом и пятом разделах рассматриваются модели обнаружения объектов и сегментации экземпляров на базе семейства YOLO. Для обнаружения на основе бинарных масок вычислялись ограничивающие прямоугольники. Оценка производилась по метрикам точности, полноты, mAP_{50} и mAP_{50-95} . Наилучшие результаты продемонстрировала модель YOLO11x, достигшая точности 0.997, полноты 0.955 и mAP_{50-95} 0.921. Высокие показатели также показала YOLO26x. Сводные метрики приведены в таблице 3:

Таблица 3 – Метрики моделей обнаружения объектов

Модель	Эпох	mAP_{50-95}	mAP_{50}	Точность	Полнота	L_{loc}
YOLOv8x	100	0.809	0.957	0.983	0.906	0.6581
YOLOv9e	100	0.779	0.945	0.956	0.894	0.7157
YOLOv10x	100	0.802	0.954	0.974	0.894	1.495
YOLO11x	800	0.921	0.98	0.997	0.955	0.535
YOLO12x	100	0.765	0.934	0.961	0.878	0.7489
YOLO26x	100	0.907	0.98	0.983	0.954	0.5391

Для сегментации экземпляров бинарные маски преобразовывались в полигональные контуры с нормализацией координат вершин. Помимо стандартных метрик, оценивалась компонента потерь маски L_{mask} . Среди обученных моделей наилучший результат по mAP_{50-95} достигнут YOLO11x-seg при точности масок 0.985 и полноте 0.962. Итоговые метрики продемонстрированы в соответствии с таблицей 4:

Таблица 4 – Результирующие метрики моделей сегментации экземпляров

Модель	Эпох	mAP_{50-95}	mAP_{50}	Точность	Полнота	L_{mask}
YOLOv8x-seg	100	0.716	0.969	0.976	0.916	1.226
YOLOv9e-seg	100	0.684	0.958	0.965	0.889	1.355
YOLO11x-seg	950	0.797	0.983	0.985	0.962	0.8451
YOLO26x-seg	100	0.781	0.984	0.975	0.958	0.9398

В шестом разделе выполнен сравнительный анализ рассмотренных подходов. Семантическая сегментация обеспечивает детальное выделение границ патологии, однако ошибки при выборе энкодера в гибридных архитектурах могут провоцировать ложные срабатывания. Модели обнаружения объектов семейства YOLO работают быстрее и пригодны для задач реального времени, но ограничивающие рамки лишь приблизительно описывают форму новообразования. Модели сегментации экземпляров сочетают точность выделения контуров с идентификацией отдельных объектов. Полученные результаты формируют основу для выбора оптимальных моделей при разработке системы инкрементального дообучения.

В третьей главе представлены результаты проектирования и разработки системы инкрементального дообучения моделей. В первом разделе рассматривается архитектура микросервиса дообучения, построенная по модульному принципу. Выделены три основных функциональных блока. Модуль данных включает коллекторы для сбора экспертных коррекций и балансировщик, формирующий репрезентативные обучающие выборки с заданным соотношением новых и исторических образцов. Балансировщик вычисляет необходимое количество исходных данных из хранилища и преобразует их в форматы, специфичные для каждой архитектуры. Подготовленная выборка разделяется на обучающую и валидационную части. Высокоуровневая архитектура микросервиса приведена в соответствии с рисунком 2:

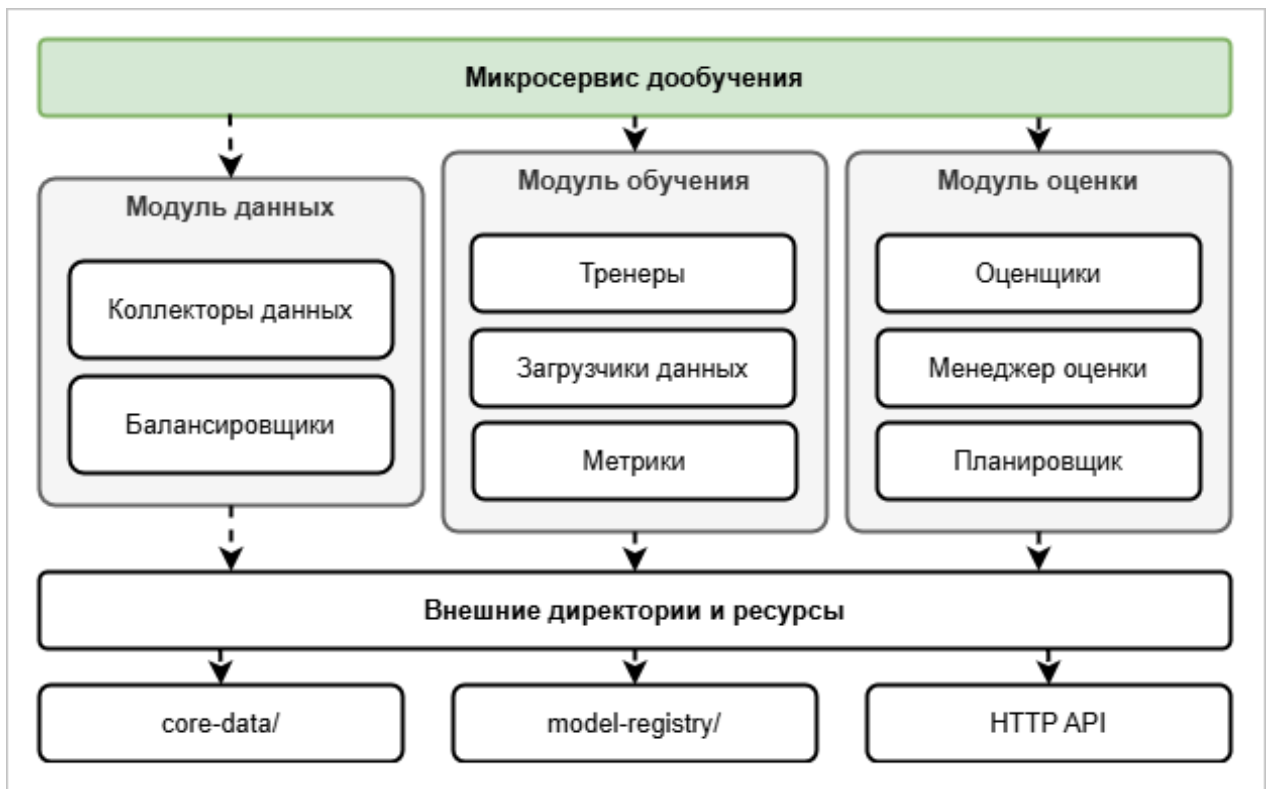


Рисунок 2 – Высокоуровневая архитектура микросервиса дообучения

Модуль обучения реализует цикл тренировки для различных архитектур, используя переданные через интерфейс гиперпараметры и стратегии заморозки слоев для смягчения катастрофического забывания. После завершения обучения активируется механизм атомарной публикации. Предыдущая версия модели перемещается в архив с индексом версии, а актуальная используется для предсказаний. Модуль оценки содержит планировщики запуска, оценщики качества на тестовых наборах и специализированный компонент для мониторинга забывания. Система загружает модели из реестра, оценивает их на тестовом наборе до и после дообучения, вычисляет падение метрик. При превышении порогового значения фиксируется катастрофическое забывание. Полный цикл работы микросервиса включает подготовку данных, дообучение, оценку, обнаружение забывания и версионирование.

Во втором разделе главы описана инфраструктура программного комплекса. Внедрена ролевая модель доступа: администратор управляет учетными записями, инженер машинного обучения настраивает и запускает дообучение, медицинский эксперт загружает снимки и корректирует предсказания. Хранение учетных записей организовано в PostgreSQL, взаимодействие с базой данных реализовано через Object-Relational Mapping (ORM).

Четвертая глава описывает графический интерфейс диагностического комплекса, реализующий взаимодействие с пользователями различных ролей. В первом разделе представлена панель администратора для управления пользователями: создание новых учетных записей с назначением роли, сброс пароля, поиск по электронной почте. Медицинский специалист после аутентификации получает доступ к диагностическому интерфейсу, где может загрузить снимок. Система выполняет предсказание с использованием выбранной модели, отображая исходное изображение, результат сегментации или обнаружения. Предусмотрена фильтрация результатов по типу модели. Для коррекции предсказаний реализованы специализированные редакторы. Редактор масок позволяет добавлять или удалять области, регулировать сглаживание границ и изменять цветовую палитру наложения. Редактор ограничивающих прямоугольников дает возможность изменять положение и размер рамки. Работа в редакторах сопровождается анимированной инструкцией.

Инженер машинного обучения через пользовательский интерфейс может настроить параметры дообучения. Например, коэффициент буфера повторения, порог минимального числа коррекций, порог обнаружения забывания, выбор категории моделей, количество эпох, размер мини-выборки, процент замороженных слоев, скорость обучения и другие параметры. После запуска процесса система отображает динамику изменения ключевых метрик на аналитической платформе с использованием графиков и столбчатых диаграмм. Все результаты логируются и доступны в табличном виде. Интерфейс адаптирован для различных устройств.

Во втором разделе главы рассматривается система мониторинга работы программного комплекса в реальном времени. Для сбора и хранения метрик состояния сервисов используется Prometheus, периодически опрашивающий микросервисы авторизации и дообучения, а также специализированные адаптеры. Текстовые журналы собираются связкой Promtail и Loki. Визуализация данных осуществляется в Grafana, где настроены информационные панели для контроля загрузки центрального процессора, оперативной памяти, дискового пространства, состояния системы кэширования Redis, S3-хранилища MinIO и баз данных PostgreSQL. Такой подход помогает контролировать отказоустойчивость системы, а именно оперативно выявлять сбои и анализировать нагрузку на компоненты системы.

ЗАКЛЮЧЕНИЕ

В рамках исследования была спроектирована и реализована интеллектуальная система анализа МРТ-изображений головного мозга с возможностью дообучения. Анализ существующих решений и коммерческих платформ позволил выделить ряд недостатков. Например, зависимость точности от условий получения снимков, отсутствие адаптации к новым данным и недостаточная интерпретируемость решений. Обоснована необходимость разработки системы, сочетающей инкрементальное обучение, объяснимый искусственный интеллект и вовлечение медицинского специалиста в процесс коррекции результатов работы моделей.

Исследованы архитектуры сверточных нейронных сетей для семантической сегментации. Лучший результат по коэффициенту Dice показала сеть FPN со значением метрики более 91%. Для обнаружения объектов и сегментации экземпляров обучены модели семейства YOLO. Наилучшие показатели достигнуты YOLO11x в задаче детекции с точностью выше 99% и YOLO11x-seg в задаче сегментации экземпляров с полнотой более 96%.

Сформулированы требования к системе инкрементального обучения. Разработана модульная микросервисная архитектура. Система состоит из конвейера сбора коррекций, балансировки данных и обучения моделей. Для хранения исходного набора данных, внесенных коррекций и весов использовано S3-совместимое хранилище MinIO. Реализованы редакторы масок и ограничивающих прямоугольников с функциями добавления и удаления областей. Разработанная система компенсирует недостатки существующих платформ. Инкрементальное обучение адаптирует модели к новым данным без утраты ранее усвоенных знаний. Режим совместной работы с возможностью коррекции предсказаний усиливает контроль качества.

Результаты работы были представлены на XVI научно-практической конференции «Presenting Academic Achievements to the World-2025» на английском языке. Доклад занял первое место в секции «Computer Science, IT and Economics II». Статья принята к публикации в сборнике материалов конференции. Также материалы исследования были изложены на Студенческой научной конференции 2026 года факультета компьютерных наук и информационных технологий СГУ. Полученные результаты формируют практическую основу для создания самообучающихся систем в области анализа МРТ.