DOI: 10.15514/ISPRAS-2026-38(6)-44

Генерация синтетических маммограмм по структурированным характеристикам исследования и оценка их применимости для обучения классификаторов

Е.Н. Ушаков, ORCID: 0000-0001-8370-6911 <ushakov@ispras.ru>
Е.С. Земнухов, ORCID: 0009-0003-0067-0063 <e.zemnukhov@ispras.ru>
С.Н. Зимина, ORCID: 0000-0002-3777-1007 <zimina@ispras.ru>
Я.М. Подмарев, ORCID: 0009-0002-3772-3993 <podmarev.iam@phystech.edu>
А.А. Литвинов, ORCID: 0009-0000-3561-3817 <filashkov@ispras.ru>
Е.А. Карпулевич, ORCID: 0000-0002-6771-2163 <karpulevich@ispras.ru>
Институт системного программирования им. В.П. Иванникова РАН,
Россия, 109004, г. Москва, ул. А. Солженицына, д. 25.

Аннотация. Рассматривается задача генерации синтетических маммографических изображений с использованием структурированных характеристик исследования и последующего применения таких изображений для расширения обучающей выборки классификатора. Практическая значимость задачи определяется высокой стоимостью разметки маммограмм, неравномерным распределением примеров по классам и необходимостью сохранять диагностически значимые детали. В качестве экспериментальной базы использован открытый набор VinDr-Mammo; классификатор разделяет изображения категории BI-RADS 5-6 и категорий BI-RADS 1 и 2. Условие генерации формируется из проекции, стороны исследования, плотности ткани, категории BI-RADS и типов находок; генератор основан на Stable Diffusion v1.5. Сопоставлены шесть режимов обучения классификатора: на реальных изображениях, на реальных данных с четырьмя объёмами синтетического дополнения и исключительно на синтетических данных. Базовый классификатор достиг значений метрик ROC AUC 0,9948 и F1 0,8966. Синтетическое дополнение повысило значение ROC AUC на 0,0034 (до 0,9982), а при дополнении 25% и 50% полнота увеличилась с 0,8478 до 0,8913. Наибольшее дополнение снизило полноту до 0,7391, а обучение исключительно на синтетических маммограммах дало значения ROC AUC 0,8898 и F1 0,3077.

Ключевые слова: синтетические маммограммы; условная генерация изображений; набор данных VinDr-Mammo; диффузионные модели; расширение обучающих данных; классификация изображений; ROC AUC; неравномерность распределения классов.

Для цитирования: Ушаков Е.Н., Земнухов Е.С., Зимина С.Н., Подмарев Я.М., Литвинов А.А., Карпулевич Е.А. Генерация синтетических маммограмм по структурированным характеристикам исследования и оценка их применимости для обучения классификаторов. Труды ИСП РАН, 2026, том 38, вып. 6, часть 2, стр. 385–394. DOI: 10.15514/ISPRAS-2026-38(6)-44.

Благодарности: Работа выполнена в Лаборатории программных систем в биомедицине ИСП РАН при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках государственного задания № 075-00220-26-04 (шифр темы FFMZ-2026-0001).

Conditional Generation of Synthetic Mammograms from Structured Examination Attributes and Evaluation of Their Utility for Classifier Training

E.N. Ushakov, ORCID: 0000-0001-8370-6911 <ushakov@ispras.ru>
E.S. Zemnukhov, ORCID: 0009-0003-0067-0063 <e.zemnukhov@ispras.ru>
S.N. Zimina, ORCID: 0000-0002-3777-1007 <zimina@ispras.ru>
I.M. Podmarev, ORCID: 0009-0002-3772-3993 <podmarev.iam@phystech.edu>
A.A. Litvinov, ORCID: 0009-0000-3561-3817 <filashkov@ispras.ru>
E.A. Karpulevich, ORCID: 0000-0002-6771-2163 <karpulevich@ispras.ru>
Ivannikov Institute for System Programming of the Russian Academy of Sciences,
25, Alexander Solzhenitsyn st., Moscow, 109004, Russia.

Abstract. This paper studies the generation of synthetic mammographic images conditioned on structured examination attributes and their use for enlarging the training set of an image classifier. The task is motivated by the high cost of mammogram annotation, the marked class imbalance, and the need to preserve subtle diagnostically important details. The experiments use the public VinDr-Mammo dataset, and the classifier separates BI-RADS 5 images from BI-RADS 1–2 images. The generation condition is composed of the mammographic view, laterality, breast density, BI-RADS category and finding types, and the generator is based on Stable Diffusion v1.5. Six classifier training settings are compared: real images only, real images supplemented with four different amounts of synthetic data, and synthetic images only. The real-only baseline reaches an area under the ROC curve of 0.9948 and an F1 score of 0.8966. Synthetic augmentation increases the area under the ROC curve in every mixed setting, by up to 0.0034 (to 0.9982), and adding 25% or 50% synthetic data raises recall from 0.8478 to 0.8913, reducing the number of missed positive cases. The largest augmentation shifts the classifier towards the highest precision and specificity, with recall of 0.7391. A classifier trained exclusively on generated mammograms, without a single real image, achieves an area under the ROC curve of 0.8898 and an F1 score of 0.3077. The results show that attribute-conditioned synthetic mammograms are an effective means of supplementing real training data for the detection of a rare positive class.

Keywords: synthetic mammograms; conditional image generation; VinDr-Mammo; diffusion models; data augmentation; image classification; ROC AUC; class imbalance.

For citation: Ushakov E.N., Zemnukhov E.S., Zimina S.N., Podmarev Ya.M., Litvinov A.A., Karpulevich E.A. Conditional Generation of Synthetic Mammograms from Structured Examination Attributes and Evaluation of Their Utility for Classifier Training. Trudy ISP RAN/Proc. ISP RAS, 2026, vol. 38, issue 6, part 2, pp. 385–394 (in Russian). DOI: 10.15514/ISPRAS-2026-38(6)-44.

Acknowledgements. This work was carried out at the Laboratory of Software Systems in Biomedicine of the Ivannikov Institute for System Programming of the Russian Academy of Sciences (ISP RAS) with financial support from the Ministry of Science and Higher Education of the Russian Federation under State Assignment No. 075-00220-26-04 (project code FFMZ-2026-0001).

1. Введение

Алгоритмы анализа маммографических изображений разрабатываются для решения задач обнаружения подозрительных изменений и классификации исследований. Качество таких алгоритмов в значительной степени определяется не только архитектурой классификатора, но и составом обучающих данных. В реальных выборках изображения разных категорий представлены неравномерно, а получение согласованной экспертной разметки требует существенных ресурсов. Это ограничивает число примеров редких состояний и затрудняет проверку устойчивости моделей при изменении состава данных.

Маммограмма обладает особенностями, усложняющими её синтез: большая размерность изображения, неоднородная текстура железистой ткани, вариации формы и плотности, а

также сравнительно небольшие диагностически значимые структуры. Изображение, визуально напоминающее маммограмму, не обязательно сохраняет признаки, по которым классификатор отличает различные категории исследований. Поэтому реалистичность синтетических изображений не может рассматриваться как единственный критерий их пригодности.

Одним из способов расширения обучающего набора является генерация дополнительных изображений. В отличие от простых геометрических преобразований и изменений яркости генеративные модели способны создавать новые варианты расположения анатомических структур и сочетаний визуальных характеристик. При этом важно задавать контролируемые признаки: проекцию исследования, сторону, категорию плотности ткани, диагностическую категорию и тип выявленных изменений. Такое описание помогает формировать изображение с требуемыми характеристиками и связывать генерацию с исходной разметкой.

Однако увеличение числа примеров само по себе не гарантирует повышения качества. Синтетические изображения могут изменять границу принятия решения, усиливать смещение в пользу преобладающего класса или воспроизводить упрощённые особенности обучающего распределения. Более того, улучшение ранжирования объектов, оцениваемое ROC AUC, не обязано сопровождаться ростом чувствительности при фиксированном пороге классификации. Для медицинских задач это различие особенно существенно.

Цель настоящей работы – исследовать применимость синтетических маммограмм, генерируемых по структурированным характеристикам исследования, для расширения обучающих наборов классификатора. Основное внимание уделяется экспериментальной постановке, количественному сравнению разных объёмов синтетического дополнения и анализу компромиссов между значениями метрики ROC AUC (Area Under the Receiver Operating Characteristic Curve), точностью положительных предсказаний и полнотой выявления положительного класса. Рассматриваются только маммографические данные открытого набора VinDr-Mammo; работа развивает результаты диссертационного исследования [1].

2. Генерация маммографических изображений: особенности и связанные работы

Существующие подходы к синтезу маммограмм условно делятся на генерацию целого изображения и локальное изменение заданной области. В первом случае модель создаёт как общий анатомический контекст, так и мелкие детали. Во втором окружающая ткань сохраняется, а изменяется только область интереса, например участок с предполагаемой находкой. Локальное редактирование удобно при создании контролируемых вариантов исходного изображения, но не даёт полностью синтезированного исследования.

В ранних работах применялись генеративно-состязательные сети. В частности, Korkinof и соавторы исследовали прогрессивный синтез маммографических изображений высокого разрешения [2]. Wu и соавторы рассматривали условное заполнение области изображения для расширения обучающих данных маммографического классификатора [3]. Более поздняя архитектура MAMBO использует раздельное моделирование общего контекста и фрагментов высокого разрешения [4]. Такие подходы показывают, что качество мелких структур зависит от того, на каком уровне разрешения выполняется синтез и как обеспечивается согласованность локальных участков.

Диффузионные генеративные модели формируют изображения посредством последовательного восстановления из зашумлённого представления. Использование пространства скрытых представлений позволяет снизить стоимость обработки изображений высокой размерности [5]. Для маммографии важна возможность учитывать не только категорию изображения, но и набор связанных с исследованием характеристик. Вместе с тем

включение клинической характеристики в условие не означает автоматического выполнения этой характеристики на каждом синтезированном изображении: соответствие результата условию требует отдельной проверки.

Открытый набор VinDr-Mammo содержит цифровые маммограммы, категориальные оценки и сведения о выявленных изменениях [6]. Его структура делает возможным подготовку входных условий без использования свободного врачебного отчёта. С ним также связаны исследования многопроекционной классификации, в частности MamT4 [7], и генерации синтетических изображений в контексте конфиденциальности [8].

3. Экспериментальные данные и организация исследования

3.1 Исходная выборка VinDr-Mammo

Экспериментальное исследование выполнено на наборе VinDr-Mammo [6], содержащем 20000 изображений 5000 исследований с официальным разбиением на обучающую (4000 исследований) и тестовую (1000 исследований) части. Классификатор решает задачу разделения на два класса: положительный класс образуют изображения категории BI-RADS 5-6, отрицательный – изображения категорий BI-RADS 1 и 2. Изображения категорий BI-RADS 3 и 4 исключены из всех выборок, реальных и синтетических.

Для классификатора длинная сторона изображения приводится к 1024 пикселям с сохранением пропорций, после чего изображение дополняется чёрным фоном до квадрата 1024×1024 пикселя. Реальные изображения считываются из исходных файлов стандартного формата DICOM; синтетические изображения размером 1024×832 пикселя дополняются до квадрата так же, так что пропорции нигде не искажаются.

Для обучения генеративной модели из исходной обучающей выборки были отобраны 4095 изображений (BI-RADS 1 – 2003, BI-RADS 2 – 691, BI-RADS 3 – 664, BI-RADS 4 – 573, BI-RADS 5 – 164). Этот объём принят за 100% синтетического дополнения. Соответственно, варианты 25%, 50% и 200% содержат 1024, 2048 и 8190 изображений. Указанные проценты описывают шкалу дополнения относительно подвыборки, использованной для генерации.

3.2 Условия генерации синтетических маммограмм

В отличие от генерации по произвольному текстовому описанию врача-рентгенолога условие в рассматриваемом опыте непосредственно формируется из доступных структурированных характеристик маммографического исследования (табл. 1). Характеристики записываются в строку заданного формата, например «MLO | R | density C | BI-RADS 5 | mass». Тем самым генератор получает не произвольный текст, а компактное описание характеристик, которые должны учитываться при построении синтетического изображения.

Табл. 1. Признаки, используемые при задании условия генерации маммограммы.
Table 1. Attributes used to condition mammogram generation.

Признак	Содержание	Роль в генерации
Проекция	CC или MLO	Геометрия и укладка
Сторона	Левая или правая	Указание стороны исследования
Плотность	Категория плотности ткани (A–D)	Структура ткани на изображении
BI-RADS	Категория оценки (1–5)	Заданная категория оценки
Тип находки	Характеристика выявленного изменения	Уточнение характера изменения

Проекция и сторона определяют геометрию изображения. Категория плотности характеризует структуру ткани и существенно влияет на внешний вид маммограммы. BI-RADS отражает итоговую оценку исследования, а тип находки задаёт дополнительную клиническую характеристику. Эти характеристики имеют различное назначение; подмена одного другим может привести к несоответствию заданного условия и внешнего вида синтезированного изображения.

В качестве генератора использована диффузионная модель со скрытым представлением изображений Stable Diffusion v1.5 [5]: вариационный автокодировщик и текстовый кодировщик CLIP не изменялись при обучении; дополнительно обучалась только сеть UNet. Модель обучалась на сформированной подвыборке при разрешении 1024×832 пикселя (снимки без растяжения дополнялись фоном до ширины 832 пикселя): 6400 шагов с общим размером пакета 128 изображений, оптимизатор AdamW, скорость обучения $1 \cdot 10^{-5}$, условие обнулялось с вероятностью 0,1 для усиления соответствия заданному условию без отдельного классификатора (classifier-free guidance). Дополнительные преобразования изображений не применялись, поскольку отражение изменило бы сторону, входящую в условие. Генерация выполнялась методом DDIM (Denoising Diffusion Implicit Models) за 50 шагов с коэффициентом усиления условия 4,0.

3.3 Варианты обучающих выборок

Условия для синтетических изображений взяты из сформированной подвыборки: каждому из 4095 реальных изображений соответствует одно синтетическое с теми же атрибутами; набор 200% получен вторым проходом по тем же условиям с другими начальными значениями генератора случайных чисел. После исключения категорий BI-RADS 3 и 4 в синтетических наборах остаётся около 70% изображений (табл. 2). Реальные и синтетические изображения объединяются без изменения весов отдельных примеров.

Для классификатора были исследованы шесть составов обучающих данных. Базовый вариант использует только реальные маммограммы. В четырёх промежуточных режимах к реальным изображениям добавляется фиксированное количество синтетических изображений. Последний вариант использует только синтетические маммограммы и позволяет оценить, насколько хорошо классификатор, обученный без реальных изображений, работает на реальных тестовых снимках.

Во всех режимах используется классификатор EfficientNet-B3, предобученный на данных из базы ImageNet, с одним выходным значением до преобразования в вероятность; функция потерь – фокальная функция потерь ($\alpha = 0{,}5$, $\gamma = 2$), оптимизатор AdamW (скорость обучения $1 \cdot 10^{-4}$), размер пакета 16 изображений, 30 эпох, стандартные преобразования геометрии и яркости изображений.

Табл. 2. Экспериментальные режимы обучения классификатора.
Table 2. Evaluated classifier training configurations.

Режим	Сгенерировано	Использовано (без BI-RADS 3–4)	Из них BI-RADS 5	Всего в обучении
R	–	–	–	14646
R+S25	1024 (25%)	715	41	15361
R+S50	2048 (50%)	1429	82	16075
R+S100	4095 (100%)	2858	164	17504
R+S200	8190 (200%)	5716	328	20362
S	4095 (100%)	2858	164	2858

4. Критерии оценки и интерпретация показателей

В качестве основной обобщающего показателя качества использована площадь под ROC-кривой (ROC AUC), характеризующая способность модели ранжировать положительные и отрицательные случаи при изменении порога принятия решения [9].

Также рассчитывались точность положительных предсказаний (Precision), полнота (Recall), специфичность (Specificity) и F1-мера [10].

Пусть TP – число истинно положительных решений, TN – истинно отрицательных, FP – ложноположительных, FN – ложноотрицательных. Тогда

$$\text{Precision} = \text{TP}/(\text{TP}+\text{FP}), \quad \text{Recall} = \text{TP}/(\text{TP}+\text{FN}), \quad \text{Specificity} = \text{TN}/(\text{TN}+\text{FP}), \tag{1}$$

$$\text{F1} = 2 \cdot \text{Precision} \cdot \text{Recall}/(\text{Precision}+\text{Recall}), \quad \text{BA} = (\text{Recall}+\text{Specificity})/2. \tag{2}$$

Полнота особенно важна для медицинского применения, поскольку её снижение соответствует увеличению числа пропущенных положительных случаев. При доле положительного класса около 1,3% общая доля правильно классифицированных изображений малоинформативна, поэтому в работе не используется.

Для каждого режима по тестовой выборке выбиралась эпоха обучения с наибольшим ROC AUC, а порог классификации – по максимуму F1 на кривой зависимости точности от полноты.

5. Результаты исследования

5.1 Сравнение режимов классификации

В табл. 3 приведены результаты классификации на реальной тестовой выборке. Все режимы с синтетическим дополнением превосходят базовый по ROC AUC; максимальные значения метрики ROC AUC получены для режима R+S50, наибольшая полнота – в режимах R+S25 и R+S50, наибольшие точность положительных предсказаний и специфичность – в режиме R+S200.

Добавление синтетических маммограмм повышает значения ROC AUC во всех смешанных режимах: 0,9979 для R+S25, 0,9982 для R+S50, 0,9952 для R+S100 и 0,9974 для R+S200 против 0,9948 для R (рис. 1). Наибольший прирост (+0,0034) достигнут при дополнении 50%; с учётом того, что базовое значение уже близко к предельному, это означает сокращение доли неверно упорядоченных пар «положительный–отрицательный» примерно на 65%. Зависимость от объёма дополнения немонотонна: наилучшие результаты дают умеренные объёмы синтетических данных (25–50%).

Режим S, обученный без единого реального изображения, достигает значения ROC AUC 0,8898. Это показывает, что генератор воспроизводит существенную часть закономерностей, по которым классификатор различает категории BI-RADS на реальных снимках.

Табл. 3. Результаты классификации на VinDr-Mammo при различных составах обучения.
Table 3. VinDr-Mammo classification results for different training sets.

Обучение	ROC AUC	F1	Точность	Полнота	Специфи-чность
R	0,9948	**0,8966**	0,9512	0,8478	0,9994
R+S25	0,9979	0,8542	0,8200	**0,8913**	0,9975
R+S50	**0,9982**	0,8723	0,8542	**0,8913**	0,9981
R+S100	0,9952	0,8667	0,8864	0,8478	0,9986
R+S200	0,9974	0,8395	**0,9714**	0,7391	**0,9997**
S	0,8898	0,3077	0,2114	0,5652	0,9732

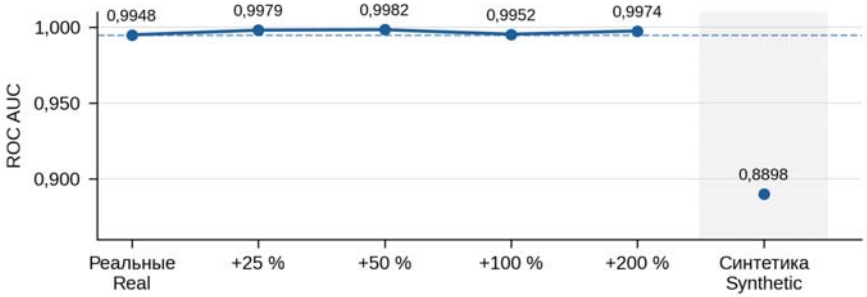

Рис. 1. Изменение ROC AUC при различных объёмах синтетического дополнения; пунктиром показан результат обучения только на реальных данных.
Fig. 1. ROC AUC for different synthetic augmentation levels; the dashed line marks the real-only baseline.

5.2 Соотношение точности положительных предсказаний и полноты

Поскольку положительных объектов в тестовой выборке мало, изменение показателей, зависящих от порога классификации имеет самостоятельное значение. На рис. 2 представлены точность положительных предсказаний и полнота для шести режимов. Базовый режим выявляет 39 из 46 положительных изображений. В режимах R+S25 и R+S50 полнота возрастает до 0,8913 (41 из 46), то есть число пропущенных случаев BI-RADS 5 сокращается с 7 до 5; при этом точность положительных предсказаний составляет 0,8200 и 0,8542. В режиме R+S200 классификатор имеет наибольшую точность положительных предсказаний: 0,9714 и специфичность 0,9997 при одном ложноположительном решении на 3616 отрицательных изображений, тогда как полнота составляет 0,7391.

В рассмотренном эксперименте объём синтетического дополнения влиял на соотношение точности и полноты: при дополнении 25–50% полнота была выше, а при дополнении 200% наблюдалось меньше ложных срабатываний. Сбалансированная точность, рассчитанная по полноте и специфичности (табл. 3), подтверждает преимущество умеренного дополнения: R+S50 (0,9447) и R+S25 (0,9444) против 0,9236 у R.

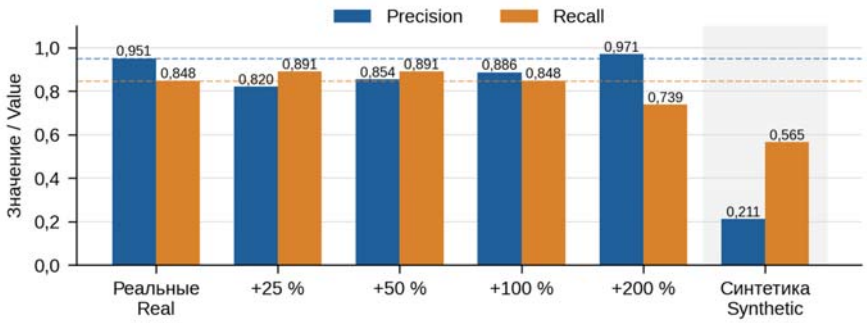

Рис. 2. Соотношение точности положительных предсказаний и полноты для различных составов обучающей выборки; пунктиром показаны значения для режима R.
Fig. 2. Precision–recall trade-off across the evaluated training configurations; dashed lines mark the real-only baseline.

5.3 Режим обучения только на синтетических маммограммах

Режим S позволяет оценить, насколько синтетические изображения самостоятельно переносят информацию о классах на реальные данные. Классификатор, не видевший ни одного реального снимка, достигает ROC AUC 0,8898, специфичности 0,9732 и выявляет 26 из 46 положительных изображений (полнота 0,5652); сбалансированная точность составляет 0,7692. Вместе с тем точность положительных предсказаний (0,2114) и F1 (0,3077) существенно ниже, чем при использовании реальных данных.

Различие может быть связано с несовпадением распределений реальных и сгенерированных изображений, неточным воспроизведением атрибутов условия и малым числом положительных синтетических примеров (164). Следовательно, в данном эксперименте дополнение реальной обучающей выборки оказалось успешнее обучения только на синтетических изображениях.

6. Обсуждение и ограничения

В проведённом эксперименте синтетическое дополнение повысило ROC AUC относительно базового режима; при дополнении 25–50% также выросла полнота выявления положительного класса. Наиболее высокие значения ROC AUC и полноты получены при дополнении 25–50%, тогда как при 200% повысилась точность положительных предсказаний, но снизилась полнота. Выбор объёма дополнения поэтому следует связывать с требованиями к полноте и числу ложноположительных решений; окончательный порог классификации необходимо определять на независимой валидационной выборке. В режиме R+S200 положительных синтетических примеров (328) больше, чем реальных (180), что могло повлиять на соотношение точности и полноты.

Проверка качества классификации на реальных снимках оценивает практическую пригодность синтетической выборки для обучения, но не подтверждает анатомическую корректность отдельных изображений.

Возможность генерации не означает автоматического исключения сведений о конкретных пациентах, что требует отдельной проверки с учётом рисков запоминания обучающих данных [12]. Наконец, приведённые показатели качества относятся к изображению как единице анализа; для многопроекционных систем, аналогичных [7], необходима проверка межпроекционной согласованности синтетических изображений.

7. Заключение

В работе рассмотрена генерация синтетических маммографических изображений с заданием структурированных характеристик исследования – проекции, стороны, категории плотности, BI-RADS и типов находок – и выполнен анализ влияния синтетических изображений на обучение классификатора BI-RADS 5-6 против BI-RADS 1–2 на VinDr-Mammo. Эксперимент включает шесть режимов и единую реальную тестовую выборку.

Синтетическое дополнение повысило ROC AUC во всех смешанных режимах, максимально – до 0,9982 при дополнении 50% против 0,9948 у базового классификатора. Дополнение 25% и 50% увеличило полноту с 0,8478 до 0,8913 и сбалансированную точность с 0,9236 до 0,9447, а наибольшее дополнение обеспечило максимальную точность положительных предсказаний (0,9714) и специфичность (0,9997). Классификатор, обученный только на синтетических данных, достиг ROC AUC 0,8898.

Таким образом, синтетические маммограммы, генерируемые по структурированным атрибутам исследования, могут дополнять реальную обучающую выборку: в проведённом эксперименте это улучшило ранжирование, а при умеренном дополнении – и полноту выявления положительного класса. Дальнейшее развитие работы связано с повышением

точности воспроизведения атрибутов условия и проверкой результатов на повторных запусках.

Список литературы / References

[1]. Ушаков Е.Н. Метод условной генерации изображений в диффузионных моделях со структурированным текстовым условием. Диссертация на соискание учёной степени кандидата физико-математических наук. М., ИСП РАН, 2026, 119 с. / Ushakov E.N. A method of conditional image generation in diffusion models with a structured text condition. Cand. Sci. (Phys.-Math.) dissertation. Moscow, ISP RAS, 2026, 119 p. (in Russian).

[2]. Korkinof D., Rijken T., O'Neill M., Yearsley J., Harvey H., Glocker B. High-resolution mammogram synthesis using progressive generative adversarial networks. arXiv, 2018. DOI: 10.48550/arXiv.1807.03401.

[3]. Wu E., Wu K., Cox D., Lotter W. Conditional infilling GANs for data augmentation in mammogram classification. In Proc. of the International Workshop on Reconstruction and Analysis of Moving Body Organs (RAMBO 2018), Lecture Notes in Computer Science, 2018, vol. 11040, pp. 98-106. DOI: 10.1007/978-3-030-00946-5_11.

[4]. Škipina M. et al. MAMBO: High-resolution generative approach for mammography images. arXiv preprint, 2025. DOI: 10.48550/arXiv.2506.08677.

[5]. Rombach R., Blattmann A., Lorenz D., Esser P., Ommer B. High-resolution image synthesis with latent diffusion models. In Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022, pp. 10684-10695. DOI: 10.1109/CVPR52688.2022.01042.

[6]. Nguyen H.T. et al. VinDr-Mammo: A large-scale benchmark dataset for computer-aided diagnosis in full-field digital mammography. Scientific Data, 2023, vol. 10, article 277. DOI: 10.1038/s41597-023-02100-7.

[7]. Ibragimov A. et al. MamT 4: Multi-view Attention Networks for Mammography Cancer Classification. 2024 IEEE 48th Annual Computers, Software, and Applications Conference (COMPSAC). IEEE, 2024, pp. 1965-1970.

[8]. Shodiev D. et al. Privacy-preserving synthetic mammograms: a generative model approach to privacy-preserving breast imaging datasets. Informatics. MDPI, 2025, vol. 12, no. 4, p. 112. DOI: 10.3390/informatics12040112.

[9]. Fawcett T. An introduction to ROC analysis. Pattern Recognition Letters, 2006, vol. 27, no. 8, pp. 861-874. DOI: 10.1016/j.patrec.2005.10.010.

[10]. Davis J., Goadrich M. The relationship between Precision-Recall and ROC curves. In Proc. of the 23rd International Conference on Machine Learning (ICML), 2006, pp. 233-240. DOI: 10.1145/1143844.1143874.

[11]. Bińkowski M., Sutherland D.J., Arbel M., Gretton A. Demystifying MMD GANs. In Proc. of the 6th International Conference on Learning Representations (ICLR). arXiv, 2018. DOI: 10.48550/arXiv.1801.01401.

[12]. Carlini N. et al. Extracting training data from diffusion models. In Proc. of the 32nd USENIX Security Symposium, 2023, pp. 5253-5270.

Информация об авторах / Information about authors

Егор Николаевич УШАКОВ – кандидат физико-математических наук, инженер-исследователь лаборатории программных систем в биомедицине ИСП РАН. Сфера научных интересов: генеративные модели, условная генерация изображений, анализ медицинских изображений, машинное обучение.

Egor Nikolaevich USHAKOV – Cand. Sci. (Phys.-Math.), Research Engineer at the Laboratory of Software Systems in Biomedicine, Ivannikov Institute for System Programming of the RAS. Research interests: generative models, conditional image generation, medical image analysis, machine learning.

Егор Сергеевич ЗЕМНУХОВ – инженер лаборатории программных систем в биомедицине ИСП РАН. Сфера научных интересов: машинное обучение, обработка биомедицинских данных.

Egor Sergeevich ZEMNUKHOV – Engineer at the Laboratory of Software Systems in Biomedicine, Ivannikov Institute for System Programming of the RAS. Research interests: machine learning, biomedical data processing.

Софья Николаевна ЗИМИНА – кандидат биологических наук, старший научный сотрудник лаборатории программных систем в биомедицине ИСП РАН. Сфера научных интересов: анализ медицинских изображений, машинное обучение.

Sofya Nikolaevna ZIMINA – Cand. Sci. (Biology), Senior Researcher at the Laboratory of Software Systems in Biomedicine, Ivannikov Institute for System Programming of the RAS. Research interests: medical image analysis, machine learning.

Яков Михайлович ПОДМАРЕВ – стажер-исследователь лаборатории программных систем в биомедицине ИСП РАН. Сфера научных интересов: машинное обучение, программные методы обработки изображений.

Iakov Mikhaylovich PODMAREV – Research Intern at the Laboratory of Software Systems in Biomedicine, Ivannikov Institute for System Programming of the RAS. Research interests: machine learning, software methods for image processing.

Арсений Александрович ЛИТВИНОВ – стажер-исследователь лаборатории программных систем в биомедицине ИСП РАН. Сфера научных интересов: анализ медицинских изображений, генеративные модели, машинное обучение.

Arsenii Aleksandrovich LITVINOV – Research Intern at the Laboratory of Software Systems in Biomedicine, Ivannikov Institute for System Programming of the RAS. Research interests: medical image analysis, generative models, machine learning.

Евгений Андреевич КАРПУЛЕВИЧ – кандидат физико-математических наук, заведующий лабораторией программных систем в биомедицине ИСП РАН. Сфера научных интересов: биоинформатика, программные системы для биомедицины, машинное обучение.

Evgeny Andreevich KARPULEVICH – Cand. Sci. (Phys.-Math.), Head of the Laboratory of Software Systems in Biomedicine at the Ivannikov Institute for System Programming of the RAS. Research interests: bioinformatics, biomedical software systems, machine learning.