

СИНТЕЗ ИЗОБРАЖЕНИЙ РАДУЖНОЙ ОБОЛОЧКИ ГЛАЗА С ИСПОЛЬЗОВАНИЕМ ГЕНЕРАТИВНО-СОСЯЗАТЕЛЬНЫХ СЕТЕЙ

Н.С. Коннова

nkonnova@bmstu.ru

SPIN-код: 3672-6670

С.М. Мартынов

martyynovsm@student.bmstu.ru

МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

В работе рассмотрены актуальные проблемы, связанные с разработкой и тестированием систем распознавания радужной оболочки глаза. Также исследованы проблемы, связанные с ограниченными наборами данных для обучения данных систем. В качестве возможного решения проведен обзор современных методов генерации синтетических изображений радужной оболочки глаза на основе GAN, анализ их сильных сторон и ограничений в создании реалистичных изображений. Представлены различные методы, применяемые для синтетической генерации радужной оболочки глаза, в частности, рассмотрены модели на основе StyleGAN, RaSGAN, CIT-GAN, iWarpGAN, StarGAN. Изображения, сгенерированные этими моделями, проанализированы на предмет реалистичности. Результаты исследования могут быть использованы при разработке, обучении и тестировании систем распознавания радужной оболочки глаза.

Ключевые слова: генеративно-состязательная сеть, синтетические радужки глаза, глубокое обучение, биометрические системы, системы распознавания, распознавание радужной оболочки глаза

Введение. Биометрические системы распознавания на основе радужной оболочки глаза в последние годы привлекли значительное внимание благодаря приложениям в таких областях, как аутентификация на смартфоне, пограничный контроль и безопасность аэропортов [1–3]. Однако по мере развития этой области возникает ряд исследовательских задач, требующих изучения и проработки [4]. В частности, важной проблемой в исследованиях биометрии является доступность наборов данных с достаточным размером, качеством и разнообразными внутриклассовыми вариациями.

Несмотря на значительные успехи биометрической технологии, наборы данных, обычно используемые для обучения и оценки этих систем, часто не соответствуют требованиям по объему выборки и включению более широкого спектра внутриклассовых вариаций (семейство наборов CASIA, IIT-Delhi Iris Dataset и др.). Этот недостаток препятствует разработке и надежной оценке систем распознавания радужной оболочки глаза. Еще одной важной задачей является обеспечение конфиденциальности лиц, биометрические

данные которых используются в исследовательских целях [5]. Биометрическая информация, будучи по своей сути персональной и уникальной, вызывает опасения по поводу несанкционированного доступа, утечек данных и потенциальной кражи личных данных. Одним из решений служит изучение потенциала синтетически сгенерированных наборов данных радужной оболочки глаза. Фактически синтетическая генерация изображений представляет собой активную область исследований в сфере распознавания отпечатков пальцев [6, 7] и распознавания лиц [8, 9].

Создание синтетических образцов радужной оболочки глаза относится к созданию цифровых изображений, которые имитируют черты и узоры, наблюдаемые на реальных изображениях радужной оболочки глаза [10, 11]. Эти синтетические образцы сгенерированы так, чтобы обладать статистическими свойствами, аналогичными реальным, предоставляя ценный ресурс для исследований, разработки и оценки в области биометрии. Генераторы синтетических изображений можно использовать для создания большего количества данных с межклассовыми и внутриклассовыми вариациями. Это помогает преодолеть ограничения и проблемы, связанные с обычными наборами данных радужной оболочки глаза. Такие наборы часто страдают от ограниченных размеров выборки, отсутствия разнообразия и представляют проблемы, связанные с конфиденциальностью и обменом данными [12]. Синтетически сгенерированные радужки глаза, напротив, предлагают контролируемое и масштабируемое решение, которое может имитировать сложность и разнообразие реальных признаков радужной оболочки глаза [13].

Создавая синтетические изображения, научное сообщество может получить доступ к более крупным и разнообразным наборам данных, что облегчает комплексное тестирование и оптимизацию биометрических алгоритмов на основе радужной оболочки глаза, повышая их производительность, надежность и безопасность. Кроме того, синтетически образцы решают проблемы конфиденциальности, связанные с использованием реальных биометрических данных. Искусственная природа сгенерированных данных гарантирует, что они не связаны напрямую с каким-либо конкретным лицом, что снижает риски несанкционированного доступа или неправомерного использования личной информации. Более того, синтетически сгенерированные радужки играют решающую роль в улучшении обучения и тестирования моделей глубоких сверточных нейронных сетей (convolutional neural network — CNN).

Глубокие CNN продемонстрировали высокую производительность в различных биометрических задачах, но в значительной степени полагаются на большие маркированные наборы данных для эффективного обучения. Синтетически сгенерированные радужки могут помочь в увеличении доступности

маркированных обучающих данных путем создания синтетических образцов с известными значениями подлинности. Это облегчает создание более обширных и разнообразных обучающих наборов, что приводит к более эффективному обучению моделей CNN и более высокой точности в системах распознавания радужной оболочки глаза. Более того, синтетически сгенерированные радужки способствуют разработке надежных алгоритмов обнаружения спуфинг-атак (от англ. spoof — обман, подделка). Синтетические радужные оболочки позволяют расширить спектр модулируемых атак с различными вариациями и типами: косметические контактные линзы, напечатанные глаза, искусственные глаза и т. д. Синтетически сгенерированный набор данных позволяет обучать и оценивать алгоритмы обнаружения атак, повышая их эффективность и позволяя разрабатывать устойчивые контрмеры против развивающихся методов спуфинг-атак. Таким образом, существуют различные применения синтетически сгенерированных радужных оболочек [14]:

- разработка и тестирование: наборы данных синтетических радужных оболочек служат ценным ресурсом для разработки и тестирования алгоритмов в области биометрии;

- дополнение данных для обучения: наборы данных синтетической радужной оболочки глаза могут использоваться для дополнения наборов данных для обучения, повышая производительность систем распознавания радужной оболочки глаза;

- сохранение конфиденциальности: набор данных синтетической радужной оболочки глаза бесценен для исследований, сохраняющих конфиденциальность, и исследований, связанных с конфиденциальной биометрической информацией.

Таким образом, наборы данных синтетических радужных оболочек обеспечивают гибкость и удобство в разработке и оценке систем распознавания на основе радужной оболочки глаза и методов обнаружения атак. В этой статье выполнен обзор современных методов генерации изображений синтетических радужных оболочек глаза, сильные и слабые стороны этих методов. Таким образом, в данном обзоре будет рассмотрено:

- изучение современных методов генерации синтетических радужных оболочек глаза и объяснение их плюсов и минусов;

- оценка изображений синтетических радужных оболочек глаза, созданных современными методами, с точки зрения качества, уникальности и пригодности.

Распознавание радужной оболочки глаза. Основополагающая технология, лежащая в основе современных автоматизированных систем распознавания радужной оболочки глаза, восходит к работам Джона Догмана [15], ко-

тому приписывают разработку основных алгоритмов распознавания. В работе Догмана различные закономерности, найденные в радужной оболочке глаза, используются для безопасного и точного распознавания человека. Распознавание радужной оболочки глаза можно подразделить на четыре этапа:

- 1) сегментация радужной оболочки;
- 2) извлечение признаков;
- 3) кодирование признаков;
- 4) сопоставление.

С недавними разработками в области машинного обучения CNN нашли применение на всех четырех этапах распознавания радужной оболочки глаза. Сегментация радужной оболочки глаза и извлечение признаков особенно выиграли от применения подходов, основанных на машинном обучении, поскольку они эффективнее справляются с различными шумами в наборах данных радужной оболочки глаза. Исследования показывают, что признаки, полученные из CNN, могут эффективно захватывать сложные характеристики радужной оболочки глаза [16]. Хотя прогресс в области машинного обучения помог повысить надежность систем распознавания радужной оболочки глаза благодаря улучшению их производительности в различных условиях, отсутствие данных радужной оболочки глаза с достаточными межклассовыми и внутриклассовыми вариациями ограничивает обучение и тестирование этих систем. Поэтому необходимо исследовать область генеративных моделей для создания синтетических наборов данных радужной оболочки глаза с достаточными межклассовыми и внутриклассовыми вариациями, чтобы упростить обучение и тестирование системы распознавания радужной оболочки глаза.

Создание синтетических радужных оболочек. Как упоминалось ранее, синтетические изображения радужной оболочки глаза обладают рядом преимуществ, включая масштабируемость, разнообразие и контроль над сгенерированными данными. Некоторые из методов создания таких изображений, классифицированные на основе используемого метода, перечислены ниже:

– *синтез на основе текстуры*: эта техника широко используется для создания синтетических изображений радужной оболочки глаза. Эти методы анализируют статистические свойства реальных изображений радужной оболочки глаза и создают новые изображения на основе этой статистики [17];

– *синтез на основе морфизма*: морфируемые модели использовались для создания синтетических изображений радужной оболочки путем захвата вариаций формы и внешнего вида в статистической модели. Эти модели представляют форму и текстуру радужной оболочки с использованием низкоразмерного пространства параметров. Манипулируя параметрами, можно

создавать синтетические изображения радужной оболочки с различными характеристиками, такими как размер, форма и текстура [18];

– *синтез на основе искажения изображения*: методы искажения изображения включают применение геометрических преобразований к реальным изображениям радужной оболочки для создания синтетических изображений. Эти преобразования могут включать повороты, перемещения, масштабирование и деформации. Искажение изображения позволяет создавать синтетические изображения радужной оболочки с вариациями позы, направления взгляда и окклюзии [19];

– *генеративно-сопоставительные сети* (generative adversarial network — GAN): GAN привлекли значительное внимание для создания реалистичных и разнообразных синтетических изображений радужной оболочки глаза. GAN состоит из двух подсетей: генератор и дискриминатор [20, 21]. В настоящее время методы на основе GAN для генерации синтетических биометрических данных оказались намного лучше для захвата сложных деталей различных биометрических сигналов. Поэтому далее мы в основном сосредоточимся на этих методах и синтетических изображениях, полученных с помощью этих методов для нашего исследования и анализа.

Генеративно-сопоставительные сети. Генеративно-сопоставительная сеть (GAN) состоит из двух подсетей: генератора и дискриминатора, которые обучаются одновременно посредством сопоставительного обучения. Генератор стремится генерировать данные, такие как изображения, аудио или текст, которые неотличимы от реальных данных, в то время как дискриминатор стремится различать реальные и синтетические данные. В этом исследовании мы рассмотрим пять различных типов GAN, которые показывают наиболее многообещающие результаты.

RaSGAN. Применение средней стандартной генеративно-сопоставительной сети для синтеза радужной оболочки глаза (Relativistic Average Standard Generative Adversarial Network — RaSGAN) позволяет преодолеть недостатки традиционных GAN путем введения релятивистского дискриминатора. В стандартных GAN задача дискриминатора — отличить настоящие образцы от поддельных, а задача генератора — сгенерировать образцы, неотличимые от реальных. Однако в RaSGAN и генератор, и дискриминатор обучены учитывать относительную вероятность того, что реальная выборка более реалистична, чем синтетическая, и наоборот. Цель состоит в том, чтобы предоставить дискриминатору связь не только о реальных и синтетических образцах, но также о том, насколько реалистичен каждый образец по отношению друг к другу. Таким образом, стабильность и сходимости GAN улучшаются благодаря предоставлению более информативных градиентов как генератору, так

и дискриминатору. Было показано, что RaSGAN создает реалистичные синтетические изображения в различных областях [22].

Процесс обучения нейронной сети схематично изображен на рис. 1. Обучающие изображения для RaSGAN сначала выравниваются и обрезаются по центру с использованием центра зрачка-радужки. Обрезанные изображения размером 256×256 затем отправляются дискриминатору для обучения. Дискриминатор пытается обнаружить синтезированные изображения, в то время как генератор пытается создать более реалистичные синтетические изображения путем обратного распространения ошибки после каждой итерации обучения и обновления весов. Для каждого сгенерированного изображения рассчитывается показатель FID для оценки его качества. Этот процесс повторяется до тех пор, пока не будут созданы изображения с более низкими (т. е. лучшими) показателями FID.

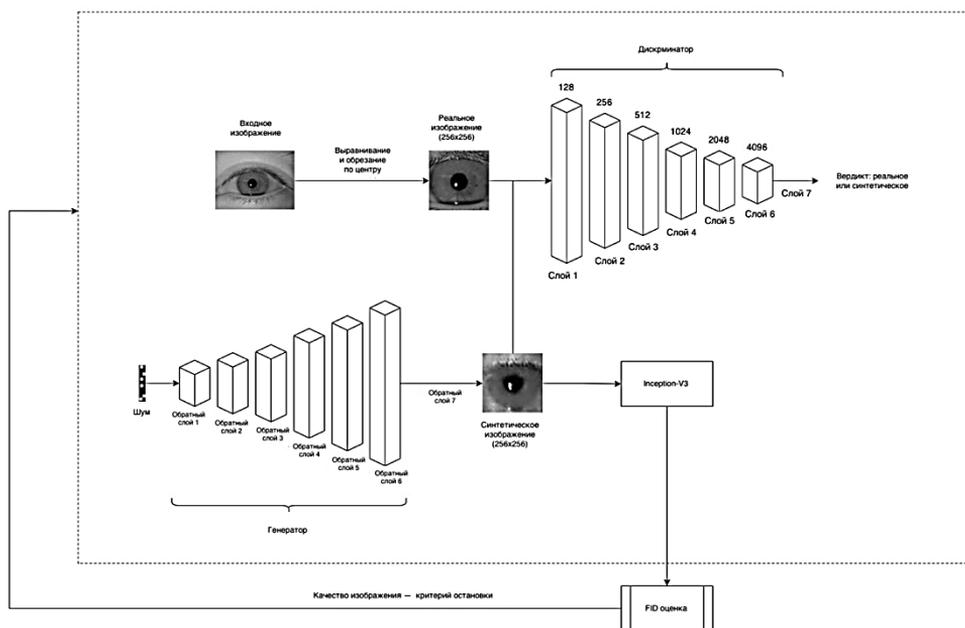


Рис. 1. Схема процесса обучения (RaSGAN) с использованием реальных изображений радужной оболочки глаза

Релятивистский дискриминатор D_R можно представить с помощью преобразованных слоев $N(x_r)$ и $N(x_s)$ как

$$D_R(x) = S(N(x_r) - N(x_s)),$$

где x_r и x_s — собой реальные и синтетические данные соответственно; $N(\cdot)$ — выходные данные последнего сверточного слоя перед применением к нему логической функции S .

Релятивистский дискриминатор D_R максимизирует вероятность того, что данное реальное изображение радужной оболочки более реалистично, чем синтетическое. Аналогично

$$D_R^{rev}(x) = S(N(x_s) - N(x_r))$$

максимизирует вероятность того, что данное синтетическое изображение радужной оболочки будет более реалистичным, чем само реальное изображение. Функции потерь для дискриминатора D_R и генератора G_R имеют вид

$$\begin{aligned} F^{RSGAN}(D_R) &= -E(x_r, x_s) \sim (\mathbf{P}_{data}, \mathbf{Q})[\ln(D_R(x))]; \\ F^{RSGAN}(G_R) &= -E(x_r, x_s) \sim (\mathbf{P}_{data}, \mathbf{Q})[\ln(D_R^{rev}(x))], \end{aligned}$$

где \mathbf{Q} — распределение синтетических данных x_s ; \mathbf{P}_{data} — распределение реальных данных x_r .

Это гарантирует, что, градиенты D_R основаны как на реальных, так и на синтетических данных. Также помогает G_R создавать более реалистичные изображения радужной оболочки.

StarGAN-v2. Вторая версия многодоменной генеративно-сопоставительной сети (Star Generative Adversial Network — StarGAN), целью которой является создание реалистично выглядящих изображений в нескольких доменах [23]. Доменами могут служить такие параметры, как узор радужной оболочки, форма зрачка и т. д. Генератор в StarGAN-v2 принимает исходное изображение и код эталонного изображения и преобразует исходное изображение в синтетическое изображение, которое имеет доменные свойства, аналогичные эталонному. Этот метод показал улучшение генерации многодоменных синтетических изображений по сравнению с результатами альтернативной сети StyleGAN [24] и предыдущей версией данной сети StarGAN-v1 [25] StyleGAN [24] и StarGAN [25]. Модули, входящие в состав сети StarGAN-v2, представлены на рис. 2.

Генератор G . Преобразует входное изображение x в выходное изображение $G(x, s)$, отражающее код стиля s , специфичный для предметной области, который предоставляется либо сетью отображения F , либо кодировщиком E . Для внедрения стиля s в генератор G используется адаптивная нормализация (adaptive instance normalization — AdaIN AdaIN).

Картографическая сеть. Учитывая латентный код z и область y , сеть отображения F генерирует код стиля $s = F_y(z)$, где $F_y(\cdot)$ обозначает выход F ,

соответствующий области y . Сеть F состоит из многослойного перцептрона (multilayered perceptron — MLP) с несколькими выходными ветвями для предоставления кодов стилей для всех доступных доменов. Сеть F может создавать коды различных стилей путем случайной выборки латентного вектора $z \in Z$ и области $y \in Y$.

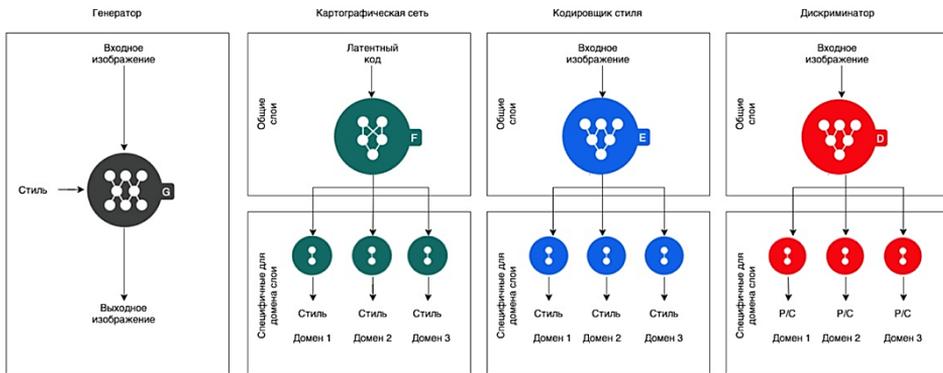


Рис. 2. Обзор модулей StarGAN-2

Кодировщик стиля. Учитывая изображение x и соответствующую ему область y , кодировщик E извлекает код стиля $s = E_y(z)$ из x . Здесь $E_y(\cdot)$ обозначает выход E , соответствующий области y . Как и F , кодировщик стилей E использует многозадачное обучение. Кодировщик E может создавать разнообразные коды стилей, используя разные эталонные изображения. Это позволяет G синтезировать выходное изображение, отражающее стиль s эталонного изображения x .

Дискриминатор D . Это многозадачный дискриминатор, который состоит из нескольких выходных ветвей. Каждая ветвь D_y , изучает бинарную классификацию, определяющую, является ли изображение x реальным изображением ее домена y или поддельным изображением $G(x, s)$, созданным G .

CIT-GAN. Генеративно-сопоставительная сеть циклического перевода изображений (Cyclic Image Translation Generative Adversarial Network — CIT-GAN) стремится преобразовать данное входное изображение в изображение из эталонной области [26]. Это преобразование происходит при помощи отдельной подсети, которая принимает эталонное изображение в качестве входных данных и активно учится генерировать синтетическое изображение, в котором четко видны свойства эталонной области. По сравнению с сетью StarGAN-v2, в которой используется картографическая сеть для генерации

кода эталонного изображения из вектора случайного шума, этот метод способен изучать внутриклассовые вариации, присутствующие в нескольких доменах. Таким образом улучшается разнообразие генерируемых изображений для каждого домена. Компоненты сети CIT-GAN показаны на рис. 3.

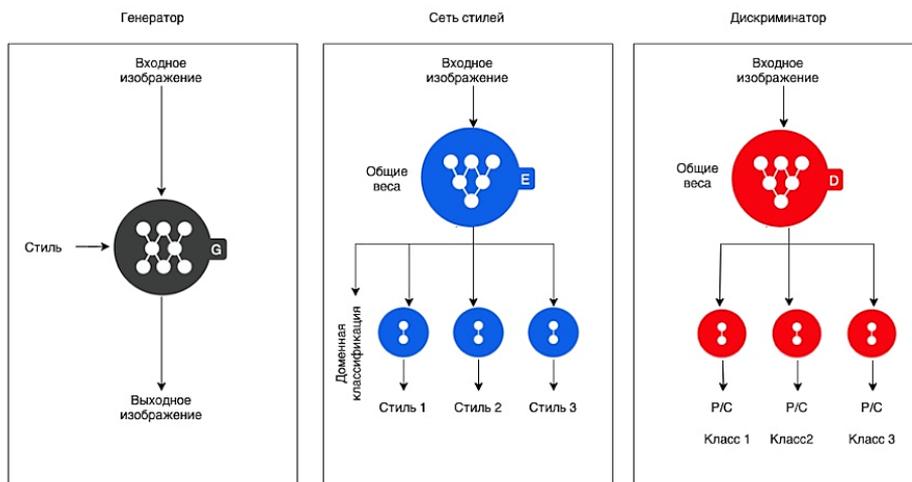


Рис. 3. Компоненты сети CIT-GAN [26]

Генератор. Для перевода *image-to-image* (изображение-в-изображение) между несколькими доменами G берет входное изображение x и преобразует его в изображение $G(x, s)$ с желаемым кодом стиля s . Код стиля s создается с помощью сети стиля Styling Network S и вводится в G .

Дискриминатор. В предлагаемой архитектуре имеет несколько ветвей, где каждая ветвь D_d решает, является ли входное изображение x реальным изображением в области d или синтетическим изображением.

Сеть стилей. Учитывая входное изображение x , принадлежащее домену d , сеть стилей S кодирует изображение в код стиля s . Подобно D , сеть стилей S представляет собой многозадачную сеть, которая изучает код стиля для входного изображения и вводит код стиля в G для генерации изображений с заданными кодами стиля.

Функция потерь имеет следующий вид:

$$L_{adv} = E_{x,d} [\ln(D_d(x))] + E_{x,d'} [\ln(1 - (D_{d'}(G(x, s'))))],$$

где $D_d(x)$ выводит решение по изображению x для доменной ветви d ; сеть стилей S берет изображение y из целевого домена d' и выводит код стиля s' ;

$G(x, s')$ генерирует изображение y' с характеристиками стиля целевого домена d' .

StyleGAN-3. Третья версия семейства стиливой генеративно-сопоставительной сети StyleGAN, которая решает проблемы предшественников, которым не хватало разнообразия генерируемых изображений и возможностей сети по обобщению, путем введения адаптивной нормализации (adaptive instance normalization — AdaIN), целью которого является улучшение способности к обобщению сети дискриминаторов. AdaIN динамически регулирует скорость увеличения данных во время обучения дискриминатора, эффективно делая дискриминатор более устойчивым к различным вариациям обучающих данных [27]. Архитектура сети StyleGAN-3 показана на рис. 4.

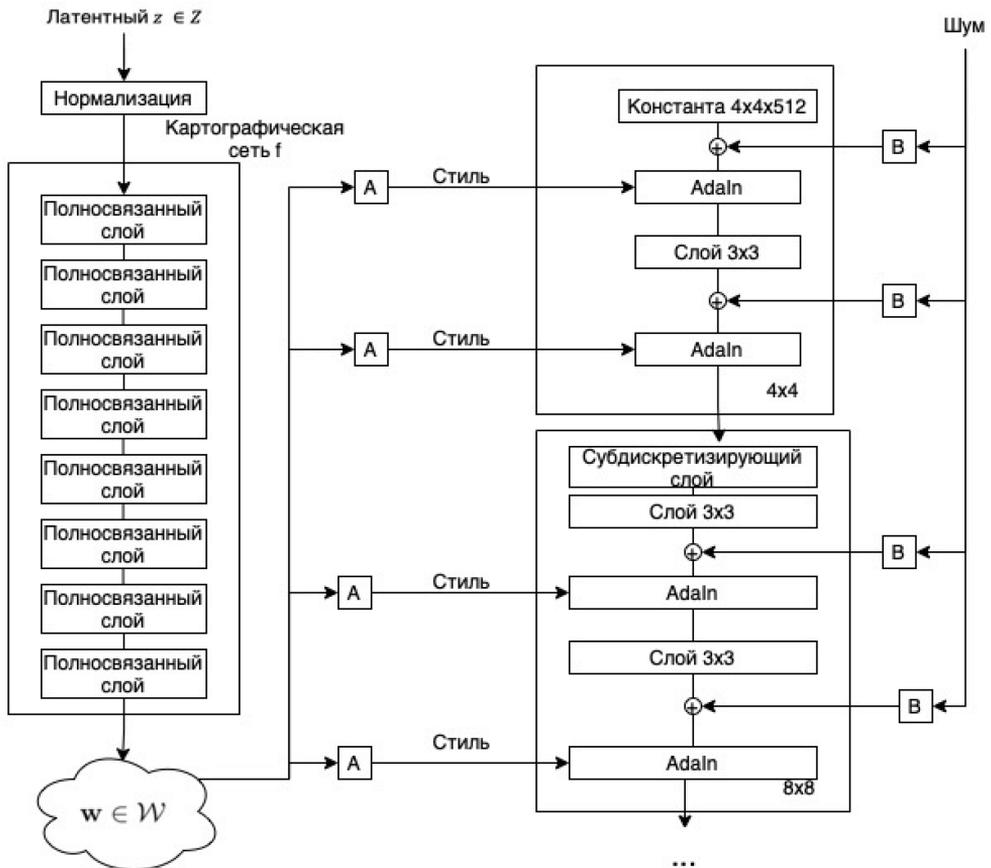


Рис. 4. Схема сети StyleGAN-3

В то время как традиционный генератор передает латентный код только через входной слой, данная сеть сначала отображает входные данные в промежуточное латентное пространство W , которое затем управляет генератором посредством адаптивной нормализации экземпляров (AdaIN) на каждом слое свертки. Гауссов шум добавляется после каждой свертки перед оценкой нелинейности. На рис. 4 блок А обозначает изученное аффинное преобразование, а блок В соответствует применению изученных поканальных коэффициентов масштабирования к входному шуму. Сеть отображения f состоит из 8 слоев, а сеть синтеза g — из 18 слоев — по два для каждого разрешения ($4^2 - 1024^2$). Выходные данные последнего слоя преобразуются в формат RGB с использованием отдельной свертки 1×1 .

iWarpGAN. Целью генеративно-сопоставительной сети для искажения радужной оболочки глаза (Iris Warping Generative Adversarial Network — iWarpGAN) является создание полностью синтетических изображений радужной оболочки глаза, т. е. изображения радужной оболочки, созданные этим методом, не похожи ни на одну радужную оболочку, используемую во время обучения. Этот метод позволяет генерировать изображения радужной оболочки глаза с уникальными свойствами на основе обучающих данных, создавать несколько изображений для каждого вновь сгенерированного изображения и масштабироваться до сотен тысяч изображений [28]. Схема сети изображена на рис. 5.

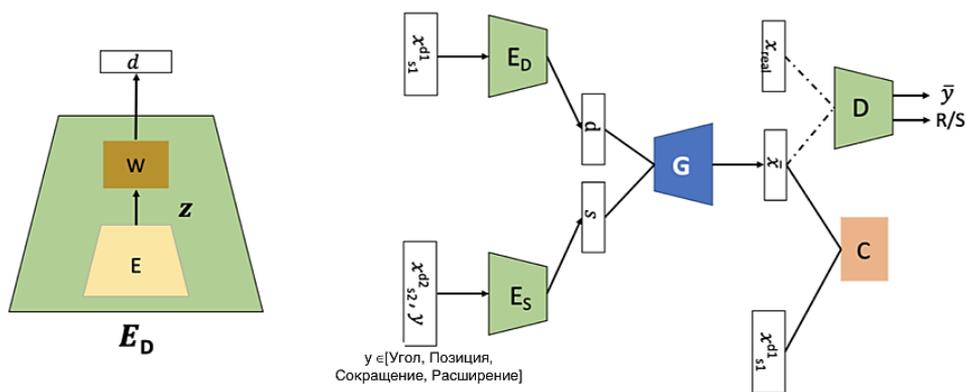


Рис. 5. Схема сети iWrapGAN

Сеть состоит из следующих компонентов:

- кодировщик стиля E_S , предназначен для кодирования стиля входного изображения;

– кодировщик идентификации E_D , его целью является изучение кодировки d , которая генерирует идентификатор, отличный от входного изображения;

– генеративная сеть G , которая использует кодировку как E_D , так и E_s для создания изображения с уникальным идентификатором и заданным атрибутом стиля;

– дискриминатор D , который получает на вход либо реальное, либо синтетическое изображение и прогнозирует, является ли изображение реальным или синтетическим, а также генерирует вектор атрибутов $y' \in \{\text{Угол, Положение, Сужение, Расширение зрачка}\}$;

– предварительно обученный классификатор C , который вычисляет оценку расстояния между реальным входным изображением и новым идентификатором, сгенерированным G .

Качество генерируемых изображений. FID. Чтобы оценить реалистичность и качество сгенерированных изображений радужной оболочки с помощью различных сетей, воспользуемся метрикой оценки качества изображений (Fréchet Inception Distance — FID) [29].

FID — это показатель, используемый для оценки качества синтетически созданных изображений путем сравнения их распределения с распределением реальных изображений, в результате чего выводится оценка, основанная на различиях:

$$\text{FID} = \|\mu_r - \mu_s\|^2 + \text{Tr}(\Sigma_r + \Sigma_s - 2\sqrt{\Sigma_r \Sigma_s}),$$

где μ_r , μ_s , Σ_r , Σ_s представляют статистику двух распределений; Tr — след матрицы ковариаций $(\Sigma_r + \Sigma_s - 2\sqrt{\Sigma_r \Sigma_s})$.

Цель состоит в том, чтобы минимизировать этот показатель, поскольку более низкое значение показателя FID предполагает большее сходство между синтетическими и реальными наборами данных. Баллы FID могут охватывать широкий диапазон, причем чрезвычайно высокие баллы в диапазоне 400–600 указывают на значительное отклонение от реального распределения данных и, как следствие, на плохое качество синтетического изображения.

Для проведения эксперимента использовался набор данных CASIA-Iris-Thousand Dataset, который состоит из 20 000 изображений реальных радужных оболочек.

В своем анализе качества синтетически сгенерированных изображений радужной оболочки глаза, полученных с помощью различных GAN и использованных в этом исследовании, исследователи Yadav и Ross [30] получили средний балл FID 24,33 для RaSGAN и StarGAN-v2. Для CIT-GAN, StyleGAN-3

и iWarpGAN были получены оценки 31,82; 26,90; 15,72 и 17,62 соответственно. Как упоминалось ранее, чем ниже показатель FID, тем более реалистичными будут сгенерированные изображения по сравнению с реальными изображениями. Таким образом, можно сделать вывод, что StyleGAN-3 и iWarpGAN генерируют наиболее реалистичные изображения радужной оболочки.

Данные результаты можно объяснить тем, что в StyleGAN-3 и iWarpGAN используется новый подход для генерации изображений: большинство GAN в основном сфокусированы только на редактировании признаков изображений, одновременно генерируя ранее замеченные признаки в наборе обучающих данных, в то время как в этих двух моделях это разделено на два подпроцесса — изучение новых признаков, которые отличаются от тех, что есть в обучающем наборе данных, и редактирование признаков для обеспечения внутриклассовых вариаций. Распределение этих оценок FID показано на рис. 6.

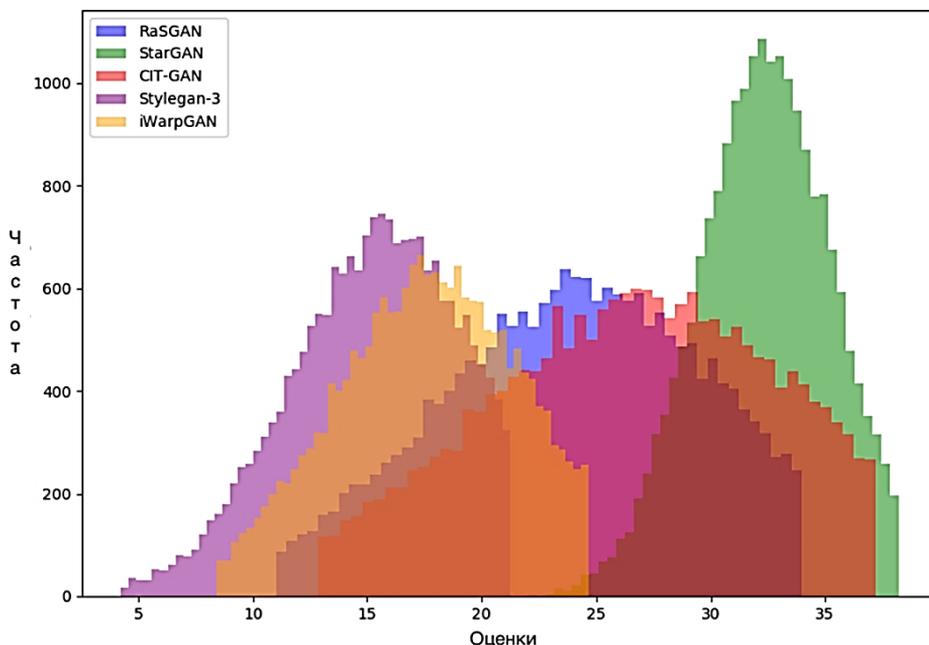


Рис. 6. Распределение оценок FID на основе сгенерированных изображений радужной оболочки глаза при обучении GAN с использованием набора данных CASIA-Iris-Thousand [30]

Примеры сгенерированных изображений изображены на рис. 7.

Стандарт ISO/IEC 29794-6:2015. Точность синтетически полученных изображений радужной оболочки также может быть оценена с использованием стандартных метрик качества ISO/IEC 29794-6 [31]. Эта оценка была применена к изображениям, созданным различными GAN, которые рассмот-

рены в этом исследовании. В стандарте ISO используется широкий набор критериев для оценки качества изображения радужной оболочки. В рамках данного исследования полученные изображения были оценены с помощью десяти основных рекомендованных метрик:

- 1) полезная площадь радужной оболочки глаза;
- 2) контраст радужки и склеры;
- 3) контраст радужки и зрачка;
- 4) округлость границы зрачка;
- 5) использование шкалы серого;
- 6) радиус радужной оболочки;
- 7) расширение зрачка;
- 8) концентричность радужной оболочки и зрачка;
- 9) границы радужной оболочки;
- 10) резкость.

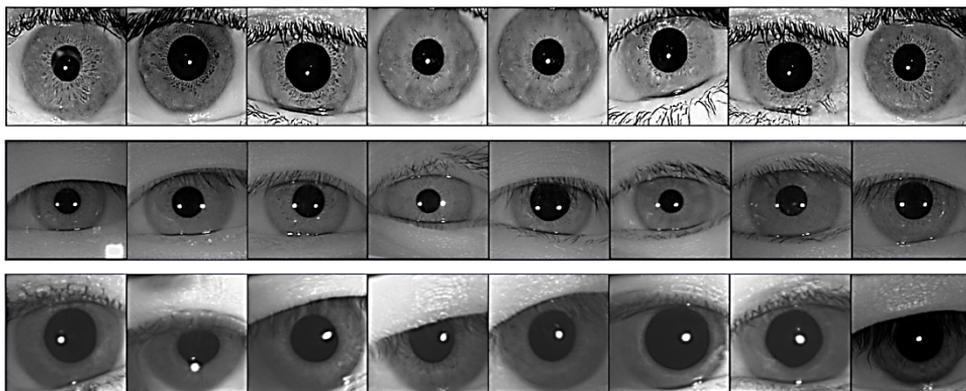


Рис. 7. Примеры сгенерированных изображений радужных оболочек глаза [30]

Методы расчета некоторых метрик сведены в таблицу. Вместе эти метрики позволяют получить объективную оценку качества изображений.

**Расчет метрик качества изображений радужной оболочки глаза
по стандарту ISO/IEC 29794-6 [31]**

| Метрика качества | Метод расчета |
|----------------------------|---------------|
| Прямой взгляд — азимут | Не определен |
| Прямой взгляд — полярность | Не определен |

Продолжение таблицы

| Метрика качества | Метод расчета |
|---|--|
| Фронтальное вращение головы | Если на изображении видна вся область глаза, то фронтальное вращение головы рассчитывается как угол, измеренный между горизонталью и линией, проведенной между левым и правым углами глаза (медиа́льный и латеральный угол глаза) |
| Использование шкалы серого | Не определен |
| Подлинность изображения | Не определен |
| Форма границы радужной оболочки | Форма границы радужной оболочки следует измерять как эксцентриситет границы радужной оболочки и склеры |
| Контраст границы радужной оболочки и зрачка | Контраст границы радужной оболочки и зрачка рассчитывается как средние различия уровней серого в местах границы радужной оболочки и зрачка вдоль горизонтального ряда пикселей, который включает центр зрачка. Это должно быть среднее арифметическое разностей значений шкалы серого на левой и правой границах радужной оболочки и зрачка |
| Концентричность радужной оболочки и зрачка | $IRIS_PUPIL_CONCENTRICITY = \frac{\sqrt{(X_{pupil} - X_{iris})^2 + (Y_{pupil} - Y_{iris})^2}}{IRIS_RADIUS},$ <p>где X_{pupil}, Y_{pupil} — координаты центра зрачка; X_{iris}, Y_{iris} — координаты центра радужной оболочки; $IRIS_RADIUS$ — радиус радужной оболочки</p> |
| Контраст границы радужной оболочки и склеры | Контраст границы радужной оболочки и склеры рассчитывается как средние различия уровней серого в местах границы радужной оболочки и склеры вдоль горизонтального ряда пикселей, который включает центр радужной оболочки. Это должно быть среднее арифметическое разностей значений шкалы серого на левой и правой границах радужной оболочки и склеры |
| Размер радужной оболочки | $IRIS_SIZE = IRIS_RADIUS,$ <p>где $IRIS_RADIUS$ — радиус радужной оболочки, или $IRIS_SIZE = (4 * IRIS_AREA) / IRIS_PERIMETRE,$ <p>где $IRIS_AREA$ — площадь радужной оболочки; $IRIS_PERIMETRE$ — периметр радужной оболочки, если не предполагается округлость</p> </p> |

Продолжение таблицы

| Метрика качества | Метод расчета |
|---------------------------|--|
| Границы радужной оболочки | <p>$MARGIN = 1 - 0.25 \cdot 1 - 0.25 \times$</p> $\times \left(\begin{matrix} LEFT_MARGIN_DEFICIENCY + RIGHT_MARGIN_DEFICIENCY + \\ + UP_MARGIN_DEFICIENCY + DOWN_MARGIN_DEFICIENCY \end{matrix} \right),$ <p>здесь</p> $X_MARGIN_DEFICIENCY = \begin{cases} 1 - X_MARGIN/0.6, & \text{если } X_MARGIN < 0.6 \\ 0, & \text{если } X_MARGIN \geq 0.6 \end{cases},$ <p>где $X = LEFT/RIGHT$; $X_MARGIN_DEFICIENCY$ — нехватка (дефицит) отступа между изображением глаза и соответствующим краем кадра справа или слева; X_MARGIN — правая/левая граница; X — право/лево;</p> $Y_MARGIN_DEFICIENCY = \begin{cases} 1 - Y_MARGIN/0.2, & \text{если } Y_MARGIN < 0.2 \\ 0, & \text{если } Y_MARGIN \geq 0.2 \end{cases},$ <p>где $Y = UP/DOWN$; $Y_MARGIN_DEFICIENCY$ — нехватка (дефицит) отступа между изображением глаза и соответствующим краем кадра сверху или снизу; Y_MARGIN — верхняя/нижняя граница; Y — вверх/низ</p> <p>и</p> $LEFT_MARGIN = \max \left\{ 0, X_{IRIS_CENTER} / IRIS_SIZE - 1 \right\},$ <p>где $LEFT_MARGIN$ — левая граница; X_{IRIS_CENTER} — координата центра радужной оболочки по оси абсцисс; $IRIS_SIZE$ — размер радужной оболочки;</p> $RIGHT_MARGIN = \max \left\{ 0, [IMAGE_WIDTH - (X_{IRIS_CENTER} + IRIS_SIZE)] / IRIS_SIZE \right\},$ <p>где $RIGHT_MARGIN$ — правая граница; X_{IRIS_CENTER} — координата центра радужной оболочки по оси абсцисс; $IMAGE_WIDTH$ — ширина изображения; $IRIS_SIZE$ — размер радужной оболочки;</p> $UP_MARGIN = \max \left\{ 0, [IMAGE_HEIGHT - (Y_{IRIS_CENTER} + IRIS_SIZE)] / IRIS_SIZE \right\},$ <p>где UP_MARGIN — верхняя граница; Y_{IRIS_CENTER} — координата центра радужной оболочки по оси ординат; $IMAGE_HEIGHT$ — высота изображения; $IRIS_SIZE$ — размер радужной оболочки;</p> $DOWN_MARGIN = \max \left\{ 0, Y_{IRIS_CENTER} / IRIS_SIZE - 1 \right\},$ <p>где $DOWN_MARGIN$ — нижняя граница; Y_{IRIS_CENTER} — координата центра радужной оболочки по оси ординат; $IRIS_SIZE$ — размер радужной оболочки</p> |
| Размытие | Не определен |

Окончание таблицы

| Метрика качества | Метод расчета |
|--|---|
| Форма границы зрачка | $PUPIL_BOUNDARY_SHAPE = \frac{2\sqrt{\pi \cdot PUPIL_AREA}}{PUPIL_PERIMETRE},$ где PUPIL_AREA — площадь зрачка; PUPIL_PERIMETRE — периметр зрачка |
| Соотношение зрачка и радужной оболочки | $PUPIL_IRIS_RATIO = PUPIL_SIZE/IRIS_SIZE,$ где расчет PUPIL_SIZE аналогичен расчету IRIS_SIZE; PUPIL_SIZE — размер зрачка; IRIS_SIZE — размер радужной оболочки глаза |
| Резкость | Согласно шкале фокусировки Даугмана |
| Отношение сигнал/шум | $SIGNAL_TO_NOISE = 0.95 \cdot _max(intensityLevel - min(intensityLevel) ,$ где уровень интенсивности intensityLevel вычисляется только для области радужной оболочки |
| Полезная область радужной оболочки | Не определен |

Результаты оценки по стандарту ISO/IEC 29794-6, полученные исследователями Yadav и Ross, представлены на рис. 9 [30].

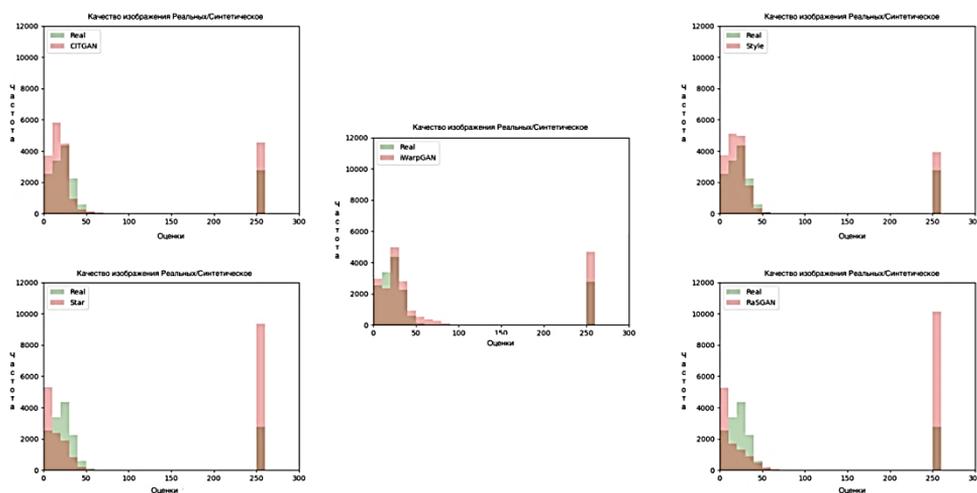


Рис. 9. Оценки сгенерированных изображений реальных (зеленым цветом) и синтетических изображений полученных при помощи различных генеративных сетей (розовым цветом) по стандарту ISO/IEC 29794-6 [30]

Оценка имеет шкалу от 0 до 100, где 0 указывает на самое низкое качество изображения, а 100 — на самое высокое. Изображениям, которые не могут быть оценены по метрике ISO, как правило, из-за нестандартного качества или ошибок в сегментации, присваивается оценка 255.

Как показано на рис. 9, оценки качества для синтетических изображений радужной оболочки глаза, полученных с использованием iWarpGAN, CIT-GAN и StyleGAN-3, находятся примерно на одном уровне с оценками реальных изображений радужной оболочки глаза. Напротив, заметному количеству изображений, созданных RaSGAN и StarGAN-V2, была присвоена оценка 255, что отражает их низкое качество. Также данный результат свидетельствует о том, что и исходные изображения, используемые для обучения нейронных сетей, имеют не лучшее качество, что может влиять на результаты и качество работы этих сетей.

Заключение. В этом исследовании рассмотрены, проанализированы и оценены различные методы GAN для создания синтетических изображений радужных оболочек глаза, которые потенциально можно использовать для обучения и тестирования систем распознавания.

Потенциальные сферы применения синтетических изображений радужной оболочки огромны и разнообразны. В системах безопасности и биометрического распознавания эти изображения могут помочь повысить точность и надежность систем, предоставляя разнообразный спектр данных для обучения и тестирования.

Хотя создание реалистичных и уникальных синтетических изображений радужной оболочки все еще находится на стадии разработки, оно предоставляет огромное поле для будущих исследований.

Литература

- [1] Vatsa N.M., Singh R. Ocular biometrics: A survey of modalities and fusion approaches. *Information Fusion*, 2015, vol. 26, pp. 1–35.
- [2] Gent E. A cryptocurrency for the masses or a universal ID? Worldcoin aims to scan all the world's eyeballs. *IEEE Spectrum*, 2023, vol. 60 (1), pp. 42–57.
- [3] Perala. *Princeton identity tech powers galaxy s8 iris scanning*. URL: <https://mobileidworld.com/princeton-identity-galaxy-s8-iris-003312> (accessed 16.11.2024).
- [4] Ross A., Banerjee S., Chen C., Chowdhury A., Mirjalili V., Sharma R., Swearingen T., Yadav S. Some research problems in biometrics: The future beckons. *Proc. of 12th IAPR International Conference on Biometrics (ICB)*. Crete, Greece, 2019, pp. 1–8.

- [5] Voigt P., Von dem Bussche A. *The EU General Data Protection Regulation (GDPR). A Practical Guide*. Cham, Springer International Publishing, 2017, chapters 10 (3152676). <https://doi.org/10.1007/978-3-031-62328-8>
- [6] Wyzkowski A.B.V., Jain A.K. Synthetic latent fingerprint generator. *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 2023, pp. 971–980.
- [7] Zhu T., Chen J., Zhu R., Gupta G. StyleGAN3: Generative networks for improving the equivariance of translation and rotation. *arXiv preprint arXiv:2307.03898*, 2023. <https://doi.org/10.48550/arXiv.2307.03898>
- [8] Fang M., Huber M., Damer N. SynthASpoof: Developing face presentation attack detection based on privacy-friendly synthetic data. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023, pp. 1061–1070.
- [9] Taherkhani F., Rai A., Gao Q., Srivastava S., Chen X., de la Torre F., Song S., Prakash A., Kim D. Controllable 3D generative adversarial face model via disentangling shape and appearance. *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 2022, pp. 826–836.
- [10] Dankar F.K., Ibrahim M. Fake it till you make it: Guidelines for effective synthetic data generation. *Applied Sciences*, 2021, vol. 11 (5), art. no. 2158.
- [11] Drozdowski P., Rathgeb C., Busch C. Sic-gen: A synthetic iris-code generator. *IEEE International Conference of the Biometrics Special Interest Group (BIOSIG)*. Darmstadt, Germany, IEEE, 2017, pp. 1–6. <https://doi.org/10.23919/BIOSIG.2017.8053520>
- [12] Khade S., Ahirrao S., Phansalkar Shr., Kotecha K. et al. Iris Liveness Detection for Biometric Authentication: A Systematic Literature Review and Future Directions. *Invention*, 2021, vol. 6.65. <https://doi.org/10.3390/inventions6040065>
- [13] Joshi I., Grimmer M., Rathgeb C., Busch C., Bremond F., Dantcheva A. Synthetic data in human analysis: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, vol. 46 (7), pp. 4957–4976.
- [14] Grosz S.A., Jain A.K. SpoofGAN: Synthetic fingerprint spoof images. *IEEE Transactions on Information Forensics and Security*, 2022, vol. 18, pp. 730–743.
- [15] Daugman J. New methods in iris recognition. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2007, vol. 37 (5), pp. 1167–1175.
- [16] Nguyen K., Fookes C., Ross A., Sridharan S. Iris recognition with off-the-shelf CNN features: A deep learning perspective. *IEEE Access*, 2017, vol. 6, pp. 18848–18855.
- [17] Shah S., Ross A. Generating synthetic irises by feature agglomeration. *IEEE International Conference on Image Processing*. Atlanta, 2006, pp. 317–320.
- [18] Wood E., Baltrusaitis T., Morency L.P., Robinson P., Bulling A. A 3D morphable model of the eye region. *Optimization*, 2016, vol. 1:0, pp. 1–17.

- [19] Cardoso L., Barbosa A., Silva F., Pinheiro A.M., Proenca H. Iris biometrics: Synthesis of degraded ocular images. *IEEE Transactions on Information Forensics and Security*, 2013, vol. 8 (7), pp. 1115–1125.
<https://doi.org/10.1109/TIFS.2013.2262942>
- [20] Bamoriya P., Siddhad G., Kaur H., Khanna P., Ojha A. DSB-GAN: Generation of deep learning based synthetic biometric data. *Displays*, 2022, vol. 74, art. no. 102267.
- [21] Bhuiyan R.A., Czajka A. Forensic Iris Image Synthesis. *IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW)*. Waikoloa, HI, USA, IEEE, 2014, pp. 1015–1023.
- [22] Yadav S., Chen C., Ross A. Synthesizing iris images using rasgan with application in presentation attack detection. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Long Beach, USA, 2019, pp. 10–20.
- [23] Choi Y., Uh Y., Yoo J., Ha J.-W. StarGAN v2: Diverse image synthesis for multiple domains. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2020, arXiv:1912.01865v2.
- [24] Karras T., Laine S., Aila T. A style-based generator architecture for generative adversarial networks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 4401–4410.
- [25] Choi Y., Choi M., Kim M., Ha J.-W., Kim S., Choo J. StarGAN: Unified generative adversarial networks for multi-domain image-to-image translation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018, pp. 8789–8797.
- [26] Yadav S., Ross A. CIT-GAN: Cyclic image translation generative adversarial network with application in iris presentation attack detection. *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 2021, pp. 2412–2421.
- [27] Karras T., Aittala M., Laine S., Harkonen E., Hellsten J., Lehtinen J., Aila T. Alias-free generative adversarial networks. *Advances in Neural Information Processing Systems (NIPS)*, 2021, pp. 852–863.
- [28] Yadav S., Ross A. iWarpGAN: Disentangling identity and style to generate synthetic iris images. *IEEE International Joint Conference on Biometrics (IJCB)*, 2023, pp. 1–10.
- [29] Salimans T., Goodfellow I., Zaremba W., Cheung V., Radford A., Chen X. Improved techniques for training GANs. *Advances in Neural Information Processing Systems (NIPS)*, 2016, pp. 2234–2242.
- [30] Yadav S., Ross A. Synthesizing Iris Images using Generative Adversarial Networks: Survey and Comparative Analysis. *arXiv:2404.17105v2*, 2024, pp. 1–25.

- [31] ISO/IEC 29794-6. *Information Technology – Biometric sample quality – Part 6: Iris image data*. 2015.

Поступила в редакцию 17.04.2025

Коннова Наталья Сергеевна — кандидат технических наук, доцент кафедры «Информационная безопасность», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

Мартынов Станислав Максимович — аспирант кафедры «Информационная безопасность», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

Ссылку на эту статью просим оформлять следующим образом:

Коннова Н.С., Мартынов С.М. Синтез изображений радужной оболочки глаза с использованием генеративно-состязательных сетей. *Политехнический молодежный журнал*, 2025, № 05 (100). URL: https://ptsj.bmstu.ru/catalog/icec/inf_tech/1067.html

SYNTHESIZING IRIS IMAGES USING GENERATIVE ADVERSARIAL NETWORKS

N.S. Konnova

nkonnova@bmstu.ru

SPIN-code: 3672-6670

S.M. Martynov

martyynovsm@student.bmstu.ru

Bauman Moscow State Technical University, Moscow, Russian Federation

Biometric systems based on iris recognition are currently used in various applications: border control, mobile devices, etc. However, research in the field of iris recognition is limited by various factors, such as relatively small sets of bonafide iris images, problems with tools for modeling potential spoofing attacks, and problems with preserving recipients' privacy. Some of these problems can be addressed by using synthetic iris images. This paper provides an overview of state-of-the-art GAN-based synthetic iris image generation methods, analyzing their strengths and limitations in generating realistic iris images that can be used for both training and testing iris recognition systems and spoofing attack detectors. In this regard, we will first review the various methods that are used for synthetic iris generation, in particular, we will consider generators based on StyleGAN, RaSGAN, CIT-GAN, iWarpGAN, StarGAN, etc. We will then analyze the images generated by these models for realism, uniqueness, and biometric usefulness.

Keywords: generative adversarial network (gan), synthetic irides, deep learning, presentation attack, iris recognition

Received 17.04.2025

Konnova N.S. — Ph. D. (Eng.), Associate Professor, Bauman Moscow State Technical University, Moscow, Russian Federation.

Martynov S.M. — Postgraduate Student, Bauman Moscow State Technical University, Moscow, Russian Federation.

Please cite this article in English as:

Konnova N.S., Martynov S.M. Synthesizing iris images using generative adversarial networks. *Politekhnicheskiiy molodezhnyy zhurnal*, 2025, no. 05 (100). (In Russ.). URL: https://ptsj.bmstu.ru/catalog/icec/inf_tech/1067.html