

ISSN 1816-0301 (print)

ОБРАБОТКА СИГНАЛОВ, ИЗОБРАЖЕНИЙ И РЕЧИ*SIGNAL, IMAGE AND SPEECH PROCESSING*

УДК 004.9

Поступила в редакцию 29.11.2017

Received 29.11.2017

В. А. Ковалев, С. А. Козловский, А. А. Калиновский*Объединенный институт проблем информатики Национальной академии наук Беларуси, Минск, Беларусь***ГЕНЕРАЦИЯ ИСКУССТВЕННЫХ РЕНТГЕНОВСКИХ ИЗОБРАЖЕНИЙ
ГРУДНОЙ КЛЕТКИ С ИСПОЛЬЗОВАНИЕМ
ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНЫХ НЕЙРОННЫХ СЕТЕЙ**

Аннотация. Рассматривается задача генерации правдоподобных (трудноотличимых от реальных) рентгеновских изображений грудной клетки человека в норме. Указанная задача решается с использованием генеративно-состязательных нейронных сетей (Generative Adversarial Nets). Степень правдоподобия получаемых результатов оценивается как визуально, так и количественно путем сравнения дескрипторов структуры изображений, основанных на локальных двоичных шаблонах.

Ключевые слова: нейронные сети, генеративно-состязательные сети, глубокое обучение, медицинские изображения, рентгеновские изображения грудной клетки

Для цитирования. Ковалев, В. А. Генерация искусственных рентгеновских изображений грудной клетки с использованием генеративно-состязательных нейронных сетей / В. А. Ковалев, С. А. Козловский, А. А. Калиновский // Информатика. – 2018. – Т. 15, № 2. – С. 7–16.

V. A. Kovalev, S. A. Kozlovski, A. A. Kalinovsky*The United Institute of Informatics Problems of the National Academy of Sciences of Belarus, Minsk, Belarus***GENERATION OF ARTIFICIAL CHEST RADIOGRAPHS USING
GENERATIVE ADVERSARIAL NEURAL NETWORKS**

Abstract. This paper deals with the problem of generating artificial chest x-ray images which expected to be almost undistinguishable from real ones. Generation was performed using Generative Adversarial Nets (GAN). Similarity of resultant artificial images to the real ones was evaluated both by visual examination and by quantitative assessment using commonly known Local Binary Patterns. It was concluded that GANs can be successfully employed for generating realistically appearing artificial chest radiographs. However, an automatic procedure of selecting “most realistic” results is necessary for excluding the final visual quality control stage and making the whole generation process fully automatic.

Keywords: neural networks, generative adversarial networks, deep learning, medical imaging, lungs x-ray images

For citation. Kovalev V. A., Kozlovski S. A., Kalinovsky A. A. Generation of artificial chest radiographs using generative adversarial neural networks. *Informatics*, 2018, vol. 15, no. 2, pp. 7–16 (in Russian).

Введение. В последние несколько лет наблюдается значительный прогресс в области разработки и использования сверточных нейронных сетей и методов так называемого глубокого, или глубинного, обучения (от англ. Deep Learning). В частности, данные методы показали высокую эффективность при решении широкого спектра задач анализа, классификации и распознавания биомедицинских изображений. Общее описание используемых подходов и примеры решения конкретных задач можно найти в обзорной публикации [1]. Результаты оценки сравнительной эффективности традиционных и нейросетевых методов решения задач класси-

фикационного и регрессионного типов на тестовой выборке рентгеновских изображений грудной клетки 10 000 здоровых людей в возрасте от 21 до 70 лет представлены в работах [2, 3]. Экспериментально показано, что использование сверточных нейронных сетей для выделения количественных признаков изображений является значительно более эффективным подходом по сравнению с традиционными методами. Так, например, при использовании нейросетевого подхода в тестовой задаче предсказания возраста человека по рентгеновскому снимку средне-квадратичная ошибка составляет 6,1 года, в то время как лучший результат, достигнутый при использовании традиционных методов, – 11,1 года, что почти в два раза хуже.

Наряду с указанными выше достоинствами современные методы глубокого обучения имеют один существенный недостаток: для эффективного обучения сверточной нейронной сети требуется очень большое количество (десятки и сотни тысяч) аннотированных изображений, что особенно трудно обеспечить в случае биомедицинских изображений. Действительно, в задачах машинного обучения, которые зачастую оперируют с обычными цифровыми фотоснимками, проблема получения большого их количества является хотя и трудоемкой, но вполне решаемой. Кроме того, ручная аннотация снимков – выделение таких целевых объектов, как люди, автомобили, здания, животные и т. п., – не требует никакой профессиональной подготовки и может осуществляться практически кем угодно.

В случае биомедицинских изображений ситуация существенно отличается от описанной выше: количество доступных изображений естественным образом ограничивается поступающим потоком пациентов, существующими возможностями и технологией накопления и цифрового архивирования данных, доступных для лечебного учреждения, уровнем компьютерной грамотности, квалификацией медицинского персонала и др. Кроме того, имеется еще целый ряд дополнительных факторов, специфичных для данной области. Например, известно, что существует большой перечень достаточно редких заболеваний и редких форм распространенных заболеваний, по которым большое количество снимков в рамках одного или нескольких родственных медицинских учреждений не может быть получено в принципе. Ситуация с ручной аннотацией медицинских изображений также гораздо более тяжелая, так как такие изображения относятся к профессиональным данным, аннотация которых может осуществляться только людьми с соответствующим специальным образованием и практическим опытом.

Целью данной работы является экспериментальное исследование возможности генерации правдоподобных рентгеновских изображений грудной клетки для их последующего использования вместо реальных изображений при решении различных практических задач. Поскольку искусственные медицинские изображения, за редким исключением, не имеют никаких законодательных и этических ограничений для распространения, они могут свободно использоваться также в учебных целях, в качестве иллюстраций в современных цифровых мультимедийных продуктах и презентациях, в виде пиктограмм в компьютерных программах и т. п.

Следует подчеркнуть, что в настоящей статье приводятся результаты лишь первого этапа исследований, направленных на разработку методов и программного обеспечения генерации правдоподобных медицинских изображений. Поэтому проблема использования получаемых искусственных изображений для обучения сверточных нейронных сетей с целью диагностики заболеваний, которая является одной из конечных целей данного направления, здесь не рассматривается.

Архитектура генеративно-сопоставительных нейронных сетей. Генеративно-сопоставительные нейронные сети (Generative Adversarial Nets, GAN) были предложены в работе [4]. Наряду с вариационным автокодировщиком [5] данный тип нейросетевых архитектур используется в качестве одного из современных методов обучения без учителя (Unsupervised Learning [4]). Как уже упоминалось выше, разработка эффективных методов обучения без учителя является одной из ключевых проблем в области глубокого обучения, так как подготовка размеченных данных – достаточно трудоемкая и дорогостоящая процедура. Классической архитектурой GAN (рис. 1) является модель с двумя модулями: генератором и дискриминатором. Задача генератора заключается в преобразовании (генерации) случайного вектора z (зачастую из равномерного распределения) в вектор более высокой размерности, соответствующий размерности реальных данных. При этом в процессе обучения модель генератора стремится подобрать внут-

ренные параметры так, чтобы выход был «похож» на примеры из имеющегося набора данных. Критерий похожести определяется другим модулем – дискриминатором. Дискриминатор в процессе обучения старается подобрать внутренние параметры так, чтобы он мог отличить данные из реального набора от данных, созданных генератором.




Рис. 1. Общая архитектура GAN

При обучении GAN каждый из модулей конкурирует с другим в процессе минимизации совместной функции ошибки $V(D, G)$, которую можно формализовать как минимакс следующим образом [4]:

$$\min_G \max_D V(D, G) = E_{p \sim p_{data}(x)} \log(D(x)) + E_{z \sim p_z(z)} \log(1 - D(G(z))),$$

где D – модель дискриминатора; G – модель генератора; x – реальные данные, набираемые из априорного распределения $p_{data}(x)$ (в рассматриваемых экспериментах это равномерное распределение); z – случайный низкоразмерный вектор, формируемый из случайного равномерного распределения $p_z(z)$.

Из-за локального характера структуры изображения (близкие пиксели коррелируют, далекие – нет) многослойная сверточная сеть является эталонным выбором в качестве архитектуры для классификации изображений [6]. Поэтому для работы с изображениями в роли дискриминатора выступает многослойная сверточная сеть. В работе [7] была представлена архитектура dcGAN (глубокая сверточная генеративно-состязательная сеть), где в качестве генератора авторы предложили применять многослойную деконволюционную («разверточную») сеть (рис. 2).




Рис. 2. Деконволюционная архитектура для модели генератора изображений

В настоящем исследовании для генерации изображений использовалась модель dcGAN в виде ее открытой реализации [8]. Как было показано в работе [7], для более стабильной сходимости процесса обучения сети необходимо использовать:

- конволюционные (сверточные) и деконволюционные (разверточные) слои с пропусками вместо операций пулинга;
- батч-нормализацию как в дискриминаторе, так и в генераторе;
- в качестве нелинейной функции активации после сверточного слоя в модели генератора функцию ReLU на всех слоях, кроме выходного, а также гиперболический тангенс на выходе;
- в качестве нелинейной функции в модели дискриминатора на всех слоях LeakyReLU.

Примеры применения генеративно-сопоставительных сетей в области биомедицинских исследований и разработок. Следует отметить, что в настоящее время количество работ, посвященных использованию GAN для генерации правдоподобных медицинских изображений, невелико. Вероятнее всего, это объясняется новизной данного подхода. Среди исследований данного направления прежде всего стоит упомянуть работу [9], которая посвящена генерации синтетических компьютерно-томографических (КТ) изображений пациентов на основе их изображений, полученных с помощью современной ядерной магнитно-резонансной томографии (МРТ). Практическая мотивация данного исследования заключается в том, что КТ-изображения необходимы для планирования локальной радиотерапии пациентов, но их съемка сама по себе предполагает получение пациентом определенной дозы рентгеновского облучения. В то же время выполнение сканирования тела при МРТ предполагает размещение пациента в магнитном поле, что практически безвредно. По результатам работы авторы делают вывод, что получаемые синтетические КТ-изображения представляют анатомию пациента достаточно точно, а алгоритм генерации КТ-изображений по МРТ-томограммам работает устойчиво. К особенностям данного исследования следует отнести тот факт, что для повышения качества результирующих КТ-изображений на этапе обучения нейронной сети авторы предлагают включать в целевую функцию градиентное изображение. В работе [10] авторы решают аналогичную задачу генерации искусственного КТ-изображения на основе МРТ-изображений, однако существенным отличием здесь является то, что на этапе тренировки сети не предполагается использование так называемых парных изображений, т. е. изображений одного и того же пациента. Кроме того, генерация трехмерных КТ-изображений осуществляется послойно, т. е. по двумерным изображениям.

Другое важное исследование данного направления [11] посвящено генерации правдоподобных изображений пациентов, получаемых с помощью позитронной эмиссионной томографии (ПЭТ), широко используемой при диагностике различных форм рака. Решение данной задачи мотивируется тем, что использование методов глубокого обучения для анализа и распознавания ПЭТ-изображений предполагает наличие значительного количества томограмм, представляющих большую вариабельность результатов ПЭТ-сканирования. Указанная вариабельность обусловлена такими факторами, как различия в типах и размерах опухолей и их локализации; естественная вариабельность анатомического строения и размеров тела разных людей; особенности, обусловленные полом и возрастом обследуемого пациента; вариабельность изображений, вызванная техническими различиями томографов от различных производителей, и др. В работе [11] эксперименты по генерации ПЭТ-изображений проводились с использованием совместных трехмерных КТ-, ПЭТ-сканов 50 пациентов, больных раком легкого. На основании этих экспериментов авторы делают вывод, что полученные искусственные изображения достаточно близки к реальным. В частности, результаты распознавания опухолей с использованием нейронной сети, натренированной на синтетических изображениях, лишь на 2,8 % хуже, чем в случае тренировки на изображениях реальных пациентов. Такие результаты выглядят многообещающе, однако в контексте настоящей работы следует подчеркнуть, что ПЭТ-изображения опухолей имеют типичный «туманный», сглаженный, слабоконтрастный вид с характерным «облачным» строением. Это коренным образом отличает их от рентгеновских снимков, представляющих анатомию тела в мельчайших деталях. В работе [12] предлагается другой подход к решению проблемы недостатка входных данных для задачи семантической сегментации МРТ-изображений агрессивного рака простаты. Суть подхода заключается в интеграции GAN в общую схему сегментации с целью своеобразного «отсеивания» неправдоподобных промежуточных вариантов на основе оценки глобальной структуры объекта. Утверждается, что получены многообещающие результаты при использовании ограниченного набора МРТ-изображений (всего лишь 152 пациентов).

Известно, что базовая задача компьютерной томографии как таковой – это задача восстановления объемного изображения по проекциям, которая относится к классу некорректно поставленных. В современных условиях естественно ожидать, что генеративные сети могут быть использованы при решении задачи восстановления в качестве своеобразного «нейросетевого регуляризационного выражения», помогающего уменьшать неопределенность, вызванную не-

хваткой данных из-за стремления уменьшить время сканирования и (или) сократить дозу облучения. В работе [13] предлагается использовать GAN при восстановлении (генерации) МРТ-изображений, которые зачастую требуют слишком много времени и, как следствие, предполагают временное обездвиживание пациента. В условиях сканирования детей показано, что время съемки изображений может быть сокращено на два порядка по сравнению с существующими методами. Известной проблемой в области анализа медицинских изображений является также автоматическая сегментация исследуемого органа, которую необходимо выполнить непосредственно перед процедурой анализа. В работе [14] рассматривается достаточно сложная задача сегментации печени на трехмерных КТ-изображениях. Следуя общей методологии связательных сетей, авторы комбинируют обычную энкодер-декодер (т. е. кодировщик-декодировщик)-сеть сегментации с дискриминационной сетью, которая «следит» за качеством результата. Предложенный метод протестирован на 1000 КТ-изображений. Показано, что новый подход обеспечивает лучшие результаты по сравнению с существующими методами сегментации печени как «в норме», так и при наличии патологии.

Исходные данные. В качестве исходных данных использовалась тестовая база цифровых рентгеновских изображений грудной клетки 10 000 здоровых людей в возрасте от 21 до 70 лет (рис. 3).




Рис. 3. Примеры исходных изображений

Возраст измерялся в количестве полных лет жизни на дату съемки. База изображений представляла собой тестовую группу, полностью сбалансированную по полу и по возрасту. В частности, на каждый конкретный год жизни из указанного выше диапазона в 50 лет были представлены снимки 200 человек (100 женщин и 100 мужчин).

Процедура генерации изображений и оценки их качества. Следует отметить, что из-за новизны исследований, использующих сверточные нейронные сети и глубокое обучение, большинство работ данного направления носит преимущественно экспериментальный характер. При отсутствии фундаментальных теоретических результатов и обоснований проблема выбора рациональных архитектур и управляющих параметров решается чаще всего экспериментально, методом проб и ошибок.

В настоящем исследовании процедура генерации правдоподобных изображений состояла из пяти основных этапов:

- формирование обучающих выборок, включающих рентгеновские снимки реальных людей;
- обучение генеративно-связательной сети с использованием различного количества эпох, т. е. с различной длительностью обучения;

– генерация искусственных рентгеновских изображений с использованием обученной генеративно-состязательной сети и различных векторов случайных чисел z в качестве входных данных;

– визуальная оценка получаемых результатов и выбор окончательной конфигурации генератора изображений;

– количественная оценка отличий реальных и искусственных изображений.

Поскольку изображения мужчин и женщин естественным образом различаются, было принято решение обучать генеративные сети для мужчин и женщин отдельно. С этой целью для обучения сетей из имеющейся базы рентгеновских снимков были выделены два сбалансированных по возрастам набора – снимки мужчин (набор 1) и снимки женщин (набор 2), по 5000 изображений в каждом наборе.

Сеть с архитектурой dcGAN [8] была обучена отдельно на наборах 1 и 2 с числом эпох от 10 до 100 с шагом 10. В результате визуальной оценки получаемых искусственных изображений было установлено, что использование 50 эпох в качестве параметра обеспечивает разумный компромисс между детальностью представления структуры искусственных изображений и необходимым разнообразием (вариабельностью) их общего вида. При малом количестве эпох наблюдался эффект «недообучения», проявляющийся в размытости, слабой контрастности генерируемых снимков. При большом количестве эпох сеть проявляла тенденцию к переобучению. Указанная тенденция проявлялась в том, что получаемые изображения становились все более и более похожи друг на друга и, как следствие, терялось естественное разнообразие, характерное для набора снимков реальных людей.

Для объективной оценки степени похожести реальных и искусственных изображений использовался метод оценки их близости в пространстве признаков на основе количественных дескрипторов. В качестве дескрипторов, описывающих структуру изображений, были выбраны так называемые локальные бинарные шаблоны (Local Binary Patterns, LBP), которые широко используются при решении самых различных задач анализа и распознавания изображений. В частности, в работе [2] было показано, что на рассматриваемой здесь базе рентгеновских снимков использование LBP-дескрипторов обеспечивает достаточно высокое качество классификации возрастных групп людей (площадь под ROC-кривой варьирует от 0,80 до 0,91 в зависимости от сравниваемых возрастных групп и типа используемого классификатора).

LBP-дескрипторы были подсчитаны для 2000 реальных и 2000 синтезированных снимков. Группа реальных снимков выбиралась равномерно, по 40 изображений для каждого года жизни в интервале от 21 года до 70 лет. Группа из 2000 синтезированных снимков формировалась путем случайного выбора из 5000 сгенерированных изображений. Для оценки степени близости дескрипторов был применен алгоритм t-SNE [15], который оценивал близость векторов признаков в терминах евклидова расстояния.

Результаты исследования. Примеры реальных и искусственных рентгеновских изображений мужчин и женщин представлены на рис. 4 и 5 соответственно.




Рис. 4. Реальные снимки грудной клетки мужчин (первый ряд – 1, 3; второй ряд – 2, 4) и сгенерированные снимки (первый ряд – 2, 4; второй ряд – 1, 3)



Рис. 5. Реальные снимки грудной клетки женщин (первый ряд – 1, 3; второй ряд – 2, 4) и сгенерированные снимки (первый ряд – 2, 4; второй ряд – 1, 3)

Результаты визуального сравнения реальных и сгенерированных изображений, представленных на рис. 4 и 5, а также сравнения большого количества изображений, проведенного авторами и их коллегами, позволяют утверждать, что синтетические изображения выглядят достаточно реалистично, разнообразно и многие из них визуально неотличимы от реальных.




Рис. 6. Распределение реальных и синтетических изображений грудной клетки мужчин (а, в) и женщин (б, г) для LBP-признаков с радиусами $R = 1$ пиксел (а, б) и $R = 4$ пиксела (в, г), редуцированное в двухмерное пространство методом t-SNE

Скаттерграммы, представленные на рис. 6, визуализируют расположение реальных изображений мужчин и женщин в пространстве признаков (зеленые треугольники) и сгенерированных (красные кольца). Для двухмерной визуализации исходное 256-мерное пространство LBP-признаков было редуцировано в эквивалентное двухмерное представление с помощью метода t-SNE. Видно, что в пространстве LBP-признаков синтетические и реальные изображения расположены достаточно близко и рассеяны стохастично, что подтверждает субъективное предположение о довольно высокой степени правдоподобия и разнообразии синтезированных изображений. Тем не менее следует отметить присутствие областей пространства, в которые попадают изображения только одной категории. Это можно объяснить тем, что, с одной стороны, синтетические изображения не подвергались никакому отбору и содержат явно неудачные экземпляры (рис. 7), а с другой – ограниченностью возможностей обученной сети, которая обусловлена сложностью обучения генеративно-состязательных сетей как таковых. Как видно из рис. 7, в некоторых случаях сгенерированные изображения демонстрируют необычную для нормы анатомию, могут иметь нетипичные затемнения в одном из легких, а также обладают некоторыми другими нехарактерными элементами.




Рис. 7. Примеры неудачных сгенерированных изображений

На рис. 6 можно также заметить, что при использовании LBP-признаков с радиусом $R = 4$, т. е. при рассмотрении более «глобальной» структуры сравниваемых изображений, схожесть сгенерированных и реальных изображений выше, чем при рассмотрении локальной структуры (межпиксельное расстояние $R = 1$). Для получения интегральных количественных оценок степени различия сгенерированных и реальных изображений решалась модельная задача классификации 4000 изображений испытываемых по полу, т. е. задача предсказания пола по рентгеновскому снимку грудной клетки, представленному его LBP-признаками (таблица).

Результаты классификации при обучении на реальных и сгенерированных изображениях

Номер строки	Классификатор	Радиус LBP	Тип изображений обучающей выборки	Точность, %
1	kNN, $k = 20$	$R = 2$	реальные	84,0
2	kNN, $k = 20$	$R = 2$	сгенерированные	64,5
3	kNN, $k = 20$	$R = 4$	реальные	84,3
4	kNN, $k = 20$	$R = 4$	сгенерированные	74,8
5	SVM	$R = 2$	реальные	80,7
6	SVM	$R = 2$	сгенерированные	60,0
7	SVM	$R = 4$	реальные	81,0
8	SVM	$R = 4$	сгенерированные	72,4

Классификация выполнялась с помощью двух известных классификаторов kNN и SVM (rbf). В первой серии экспериментов (см. нечетные строки таблицы) классификаторы обучались на выборке реальных изображений и тестировались также на независимой выборке реальных изображений. Вторая серия экспериментов (см. четные строки таблицы) была аналогична первой, за исключением того, что обучение классификаторов проводилось на искусственных изображениях. Из таблицы видно, что, несмотря на наблюдаемые флуктуации точности классификации в зависимости от параметров дескрипторов изображений и параметров классификаторов, точность классификации при обучении классификаторов на искусственных изображениях пока отстает от точности, получаемой на реальных изображениях. Данный вывод хорошо согласуется с рассмотренными выше результатами анализа распределения изображений в пространстве признаков, а также с фактом наличия среди результатов генерации неудачных экземпляров (см. рис. 7).

Заключение. Полученные результаты позволяют утверждать, что аппарат генеративно-состязательных сетей может быть использован при решении задачи синтеза правдоподобных изображений грудной клетки человека. Применение данного подхода позволяет получать изображения, которые выглядят правдоподобно как при их визуальном сравнении с реальными, так и при количественном сравнении с использованием LBP-дескрипторов.

В то же время в ходе выполнения исследования возник ряд вопросов, получить удовлетворительные ответы на которые авторам пока не удалось:

Как с помощью вектора латентных параметров z влиять на параметры конечного изображения? Например, как задавать возраст человека?

Как интерпретировать оценку близости к реальным изображениям, выдаваемую дискриминатором, которая в общем случае не соответствует визуальной оценке близости, определяемой человеком?

Каким образом реализовать процедуру автоматического отбора лучших изображений при условии, что количество генерируемых изображений практически ничем не ограничено?

Дальнейшим развитием данного направления будет проведение комплекса экспериментальных исследований для оценки возможности применения синтезированных изображений в качестве входных данных для обучения классификационных и иных моделей.

Работа была выполнена при финансовой поддержке гранта Президента Республики Беларусь (распоряжение Президента Республики Беларусь № 32рп от 19 января 2018 г.).

Список использованных источников

1. A survey on deep learning in medical image analysis / G. Litjens [et al.] // *Medical Image Analysis*. – 2017. – Vol. 42. – P. 60–88.
2. A comparison of conventional and Deep Learning methods of image classification on a database of chest radiographs / V. A. Kovalev [et al.] // *Intern. J. of Computer Assisted Radiology and Surgery*. – 2017. – Vol. 12, suppl. 1. – P. S139–S140.
3. Benchmarking the efficiency of Deep Learning methods on the problem of predicting subjects' age by chest radiographs / V. A. Kovalev [et al.] // *Proc. 3rd Intern. Conf. Big Data and Advanced Analytics*. – Minsk : BSUIR, 2017. – P. 75–82.
4. Generative Adversarial Networks / I. J. Goodfellow [et al.] // *arXiv.org* [Electronic resource]. – 2014. – Mode of access: <https://arxiv.org/pdf/1406.2661>. – Date of access: 25.09.2017.
5. Kingma, D. P. Auto-encoding variational bayes / D. P. Kingma, M. Welling // *arXiv.org* [Electronic resource]. – 2014. – Mode of access: <https://arxiv.org/pdf/1312.6114>. – Date of access: 25.09.2017.
6. LeCun, Y. Gradient-based learning applied to document recognition / Y. LeCun // *Proc. of the IEEE*. – 1998. – Vol. 86(11). – P. 2278–2324.
7. Unsupervised representation learning with deep convolutional generative adversarial networks / A. Radford, L. Metz, S. Chintala // *arXiv.org* [Electronic resource]. – 2016. – Mode of access: <https://arxiv.org/pdf/1511.06434>. – Date of access: 25.09.2017.
8. DCGAN in tensorflow [Electronic resource]. – Mode of access: <https://github.com/carpedm20/DCGAN-tensorflow>. – Date of access: 25.09.2017.
9. Medical image synthesis with context-aware generative adversarial networks / D. Nie [et al.] // *MICCAI, LNCS*. – Springer, Cham, 2017. – Vol. 10435. – P. 417–425.
10. Deep MR to CT Synthesis using Unpaired Data / J. M. Wolterink [et al.] // *arXiv.org* [Electronic resource]. – 2017. – Mode of access: <https://arxiv.org/pdf/1708.01155>. – Date of access: 22.09.2017.
11. Synthesis of Positron Emission Tomography (PET) images via multi-channel Generative Adversarial Networks (GANs) / L. Bi [et al.] // *Molecular Imaging, Reconstruction and Analysis of Moving Body Organs, and Stroke Imaging and Treatment*. – Springer, Cham, 2017. – Vol. 10555. – P. 43–51.

12. Adversarial Networks for the Detection of Aggressive Prostate Cancer / S. Kohl [et al.] // arXiv.org [Electronic resource]. – 2017. – Mode of access: <https://arxiv.org/pdf/1702.08014>. – Date of access: 28.09.2017.
13. Deep Generative Adversarial Networks for Compressed Sensing Automates MRI / M. Mardani [et al.] // arXiv.org [Electronic resource]. – 2017. – Mode of access: <https://arxiv.org/pdf/1706.00051>. – Date of access: 25.09.2017.
14. Automatic Liver Segmentation Using an Adversarial Image-to-Image Network / D. Yang [et al.] // arXiv.org [Electronic resource]. – 2017. – Mode of access: <https://arxiv.org/pdf/1707.08037>. – Date of access: 24.10.2017.
15. Van der Maaten, L. Visualizing data using t-SNE / L. Van der Maaten, G. E. Hinton // *J. of Machine Learning Research*. – 2008. – Vol. 9. – P. 2579–2605.

References

1. Litjens G., Kooi T., Bejnordi B., Setio A., Ciompi F., Ghafoorian M. A survey on deep learning in medical image analysis. *Medical Image Analysis*, 2017, vol. 42, pp. 60–88. doi: 10.1016/j.media.2017.07.005
2. Kovalev V., Kalinovsky A., Liauchuk V., Shukelovich A. A comparison of conventional and Deep Learning methods of image classification on a database of chest radiographs. *Intern. J. of Computer Assisted Radiology and Surgery*, 2017, vol. 12, suppl. 1, pp. S139–S140.
3. Kovalev V., Kalinovsky A., Liauchuk V., Shukelovich A. Benchmarking the efficiency of Deep Learning methods on the problem of predicting subjects' age by chest radiographs. *Proc. 3rd Intern. Conf. Minsk, BSUIR*, 2017, pp. 75–82.
4. Goodfellow I. J., Pouget-Adabie J., Mirza M., Xu B., Warde-Farley D., ... Bengio Y. *Generative Adversarial Networks*. ArXiv.org, 2014. Available at: <https://arxiv.org/pdf/1406.2661> (accessed 25.09.2017).
5. Kingma D. P., Welling M. *Auto-encoding variational bayes*. ArXiv.org, 2014. Available at: <https://arxiv.org/pdf/1312.6114> (accessed 25.09.2017).
6. LeCun Y. Gradient-based learning applied to document recognition. *Proc. of the IEEE*, 1998, vol. 86(11), pp. 2278–2324.
7. Radford A., Metz L., Chintala S. *Unsupervised representation learning with deep convolutional generative adversarial networks*. ArXiv.org, 2016. Available at: <https://arxiv.org/pdf/1511.06434> (accessed 25.09.2017).
8. *DCGAN in tensorflow*. Available at: <https://github.com/carpedm20/DCGAN-tensorflow> (accessed 25.09.2017).
9. Nie D., Trullo R., Lian J., Petitjean C., Ruan S. Medical image synthesis with context-aware generative adversarial networks. *MICCAI, LNCS*, 2017, vol. 10435, pp. 417–425.
10. Wolterink I. M., Dinkla A. M., Savenije M. H. F., Seevinck P.R., van den Berg C. A. T., Isgum I. *Deep MR to CT Synthesis using Unpaired Data*. ArXiv.org, 2017. Available at: <https://arxiv.org/pdf/1708.01155> (accessed 22.09.2017).
11. Bi L., Kim J., Kumar A., Feng D., Fulham M. Synthesis of Positron Emission Tomography (PET) images via multi-channel Generative Adversarial Networks (GANs). *Springer, Cham*, 2017, vol. 10555, pp. 43–51.
12. Kohl S., D. Bonekamp D., Schlemmer H. P., Yaqubi K., Hohenfellner M., Hadaschik B., Radtke J. P. *Adversarial Networks for the Detection of Aggressive Prostate Cancer*. ArXiv.org, 2017. Available at: <https://arxiv.org/pdf/1702.08014> (accessed 28.09.2017).
13. Mardani M., Gong E., Cheng J. Y., Vasawala S., Zaharchuk G., ... Xing L. *Deep Generative Adversarial Networks for Compressed Sensing Automates MRI*. ArXiv.org, 2017. Available at: <https://arxiv.org/pdf/1706.00051> (accessed 25.09.2017).
14. Yang D., Xu D., Zhou S. K., Georgescu B., Chen M., ... Comaniciu D. *Automatic Liver Segmentation Using an Adversarial Image-to-Image Network*. ArXiv.org, 2017. Available at: <https://arxiv.org/pdf/1707.08037> (accessed 24.10.2017).
15. Van der Maaten L., Hinton G. E. Visualizing data using t-SNE. *Journal of Machine Learning Research*, 2008, vol. 9, pp. 2579–2605.

Информация об авторах

Ковалев Василий Алексеевич – кандидат технических наук, заведующий лабораторией анализа биомедицинских изображений, Объединенный институт проблем информатики НАН Беларуси (ул. Сурганова, 6, 220012, Минск, Республика Беларусь). E-mail: vassili.kovalev@gmail.com

Козловский Сергей Александрович – инженер-программист, Объединенный институт проблем информатики НАН Беларуси (ул. Сурганова, 6, 220012, Минск, Республика Беларусь). E-mail: kozlovski.serge@gmail.com

Калиновский Александр Александрович – научный сотрудник, Объединенный институт проблем информатики НАН Беларуси (ул. Сурганова, 6, 220012, Минск, Республика Беларусь). E-mail: gakarak@gmail.com

Information about the authors

Vassiliy A. Kovalev – Ph. D. (Technical Sciences), Head of Laboratory of Biomedical Images Analysis, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus (6, Surganova Str., 220012, Minsk, Republic of Belarus). E-mail: vassili.kovalev@gmail.com

Sergei A. Kozlovski – Software engineer, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus (6, Surganova Str., 220012, Minsk, Republic of Belarus). E-mail: kozlovski.serge@gmail.com

Alexander A. Kalinovski – Researcher, The United Institute of Informatics Problems of the National Academy of Sciences of Belarus (6, Surganova Str., 220012, Minsk, Republic of Belarus). E-mail: gakarak@gmail.com