

Я. О. Ісаєнков<sup>1</sup>  
О. Б. Мокін<sup>1</sup>

## ТРАНСФОРМАЦІЯ ЦІЛЬОВОГО КЛАСУ ДЛЯ ЗАДАЧІ СЕГМЕНТАЦІЇ З ВИКОРИСТАННЯМ U-GAN

<sup>1</sup>Вінницький національний технічний університет

Наведено огляд сучасних генеративних змагальних моделей (ГЗМ) для аугментації даних з фокусом на дослідження створення зображень та відповідних до них сегментаційних масок. Це особливо корисно у випадках, коли даних недостатньо, вони важкодоступні, мають конфіденційний характер, або розмітка вимагає значних ресурсів. Робота спрямована на підвищення ефективності процесу аугментації міноритарного класу за рахунок перетворення зображення з іншого класу та створення сегментаційної маски. Запропоновано новий підхід до одночасної генерації зображення та сегментаційної маски з використанням генеративної змагальної мережі, де генератором виступає U-Net. Цей генератор приймає на вхід зображення одного класу та шум, який подається як додатковий канал зображення. Генератор намагається створити зображення іншого класу, мінімізуючи зміни в початковому зображенні та додаючи ознаки іншого, разом з сегментаційною маскою, нового класу. Дискримінатор же визначає, чи є пара картинка–маска реальною чи згенерованою. У моделі для збереження оригінального вигляду вхідного зображення з мінімальними змінами використовується алгоритм, який застосовує тільки ті зміни згенерованого зображення, що вказані створеною сегментаційною маскою. Це дозволяє отримати зображення з ознаками нового класу з мінімальними змінами. Апробацію запропонованого підходу виконано на наборі даних панорамних знімків зубів, на основі якого створено набір зображень окремих зубів, частина з яких з пломбами, а частина — без них. Експериментальний набір даних включає 128 зубів без пломб і 128 з пломбами. Для створення ГЗМ взято всі зображення з пломбами та без пломб і навчено генератор перетворювати зображення без пломб в аналогічні з пломбами. Для перевірки ефективності аугментації проведено два експерименти по 50 симуляцій з різним випадковим станом для тренування сегментаційної моделі U-Net на основі ResNet-34. Перший експеримент використовував тільки реальні дані для тренування, а другий включав 64 додаткові зображення та відповідні маски, створені генератором на основі наявних зображень нульового класу. Середні значення коефіцієнта Жаккара серед всіх симуляцій для першого та другого експериментів відповідно склали 94,2 та 96,1. Це свідчить про те, що дані, згенеровані за допомогою запропонованої аугментації, дійсно сприяють підвищенню якості сегментаційної моделі та цей підхід можна комбінувати разом з іншими типами аугментації.

**Ключові слова:** аугментація, генерування даних, генеративна змагальна мережа, сегментація, глибоке навчання, ГЗМ, U-GAN, U-генератор.

### Вступ

Останнім часом дифузійні моделі перевершують генеративні змагальні мережі (ГЗМ) для створення зображення, але вони є досить повільними та великими, що дає меншу свободу їхнього практичного використання у порівнянні з ефективними ГЗМ [1]. Зокрема завдяки цьому ГЗМ залишаються популярними в сфері аугментації даних, демонструючи свою універсальність і ефективність для широкого кола задач тренування моделей глибокого навчання. Підходи на основі таких моделей можуть бути особливо корисними в ситуаціях, коли дані є дефіцитними, конфіденційними або вартісними щодо процедури їхнього отримання у процесі формування тренувального набору даних.

У медичній сфері обробка зображень ГЗМ показала надзвичайну корисність, що демонструє низка досліджень. Наприклад, архітектура ГЗМ під назвою CycleGAN набула великої популярності для попередньої обробки медичних даних — автори використали велику базу даних зображень, щоб навчити CycleGAN перетворювати контрастні зображення комп'ютерної томографії в неконтрастні [2]. Застосування ГЗМ мало вагоме значення для підвищення точності вимірювання об'єму таких органів, як нирки та печінка, демонструючи перевагу ГЗМ у ефективному попередньому

обробленні медичних наборів даних. Такі відомі архітектури ГЗМ, як BigGAN [3] та StyleGAN [4], також широко використовуються для генерації додаткових даних для підвищення якості навчання.

Окремо варто відмітити ефективність використання моделі U-Net як ГЗМ-генератора [5]. Наприклад, в задачі класифікації захворювання на COVID-19 [6] автори показали, як метод на основі U-GAN використовувався для розширення набору даних для виявлення COVID-19 на рентгенівських знімках грудної клітини. Цей підхід дозволив створити великий набір синтетичних зображень для тренування, сприяючи створенню моделі, яка досягла точності понад 99 відсотків у класифікації COVID-19 на рентгенівських знімках грудної клітки. Такий підхід може бути застосований і для інших типів медичних даних, що продемонстровано авторами дослідження Generative Adversarial U-Net for Domain-free Medical Image Augmentation [7], де розроблена модель узагальнена для різних медичних зображень — експерименти проведено на восьми різноманітних наборах даних, включаючи комп'ютерну томографію, дерматоскопію, рентген тощо. Результати вказують на ефективність генералізації запропонованого методу для створення широкого спектру високоякісних медичних зображень.

Але архітектура ГЗМ на основі U-Net може вирішувати не тільки задачу генерації нових даних. Існують дослідження, які показують, що така модель може бути значно ефективнішою і для задач сегментації, демонструючи кращі результати за звичайні підходи навчання з вчителем. Результати роботи [8] показують поліпшення результатів від застосування ГЗМ з U-Net генератором для автоматичного сегментування суббазальних нервів на зображеннях, отриманих за допомогою конфокальної мікроскопії. Алгоритм порівнювали з класичним підходом навчання з вчителем на основі моделі U-Net. Авторський підхід показав вищу точність, особливо у разі сегментації зображень з шумом.

Автори роботи [9] наголошують на проблемі трудомісткості та складності задачі розмітки даних, особливо для задачі сегментації на рівні пікселів (pixel-wise segmentation), та пропонують новий варіант ГЗМ, який генерує не тільки медичні зображення, але й маски сегментації для застосування в аналізі зображень у медицині. Зокрема, вони оцінюють цей підхід на завданні сегментації легень, використовуючи рентгенівські знімки грудної клітини. Результати показали, що ГЗМ може бути корисними для синтезування даних для тренування в цій конкретній сфері. Схоже дослідження описано і в роботі [10], де авторами використано PGGAN для створення знімків комп'ютерної та магнітно-резонансної томографії. Автори демонструють доцільність впровадження синтетичних даних, отриманих від GAN, до навчальних наборів даних у двох завданнях сегментації мозку, що призводить до підвищення коефіцієнта подібності Дайса від 1 до 5 відсотків за різних умов, при цьому найбільший ефект спостерігається у випадках, коли доступно менше десяти навчальних прикладів.

В дослідженні [11] описано підхід генерації нових зображень та їхніх масок сегментації з використанням під час навчання лише однієї навчальної пари. У такій постановці запропонована ГЗМ забезпечує синтез структурного розмаїття, зберігаючи фотореалізм вихідних зображень і точну сумісність створених масок сегментації зі згенерованим вмістом.

Ще одним корисним напрямком є трансформація наявних зображень цільового домінуючого класу, який має більше прикладів, у мінорний клас, який має малу кількість прикладів. Автори [12] застосовують CycleGAN для створення зображення з протилежного класу для будь-якого вхідного зображення. Після навчання мережі вони використали його для створення зображень мінорного класу для кожного зображення в заданому незбалансованому наборі даних, таким чином перетворюючи його на повністю збалансований. Запропонована техніка доповнення може бути використана як етап попереднього оброблення в задачах бінарної класифікації. Показано, що це підвищує ефективність виявлення наявності чи відсутності пневмонії на рентгенівських зображеннях.

Ці приклади підкреслюють широке застосування GAN для аугментації та створення додаткових даних. Їхня здатність генерувати реалістичні та високоякісні синтетичні дані допомагає вирішувати ключові проблеми дефіциту та різноманітності даних. Це визначає їхню високу ефективність як інструмента поліпшення моделей машинного навчання у різних наукових та дослідницьких напрямках.

### **Трансформація класу з використанням U-GAN**

У цьому розділі докладно описано метод трансформації зображень з одного класу (наприклад, зображення здорових зубів, легень або клітин) у зображення іншого класу та створення додаткової маски, яка чітко визначає цей об'єкт (наприклад, пломба в зубах, запалення в легенях чи аномалії

в клітинах). Цей підхід може бути корисним у випадках, коли виникає необхідність створення моделі, проте присутній сильний дисбаланс за класами, що є досить поширеною ситуацією.

### Опис підходу

Архітектура розробленого методу показана на рис. 1. Набір даних розподіляється на дві вибірки відповідно до класу: дані нульового класу та дані першого класу, що мають відповідну сегментаційну маску. До даних класу 0 додається випадковий шум, розмір якого відповідає розмірності вхідного зображення. Для цього створюється вектор випадкових значень, розмір якого дорівнює ширині зображення, і цей вектор дублюється до розмірності висоти, утворюючи квадратну матрицю зі смуг відтінків сірого. Цей шум додається як додатковий канал до зображення, забезпечуючи кожній генерації унікальні риси (різне розташування або форма пломби), зумовлені додаванням випадкової інформації на початку. Для кольорових RGB зображень цей додатковий канал є четвертим, а за використання зображень у відтінках сірого — другим.

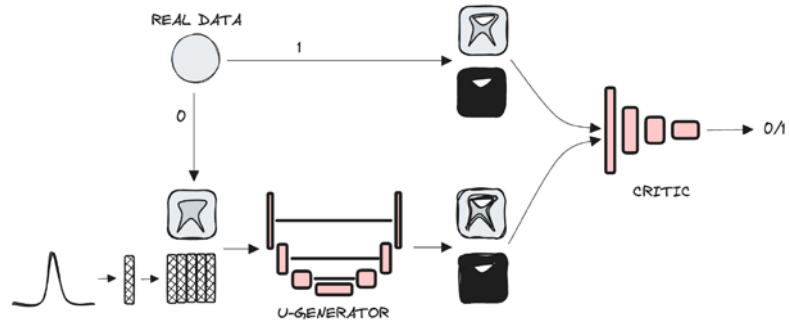


Рис. 1. Схема тренування моделі

Генератор має архітектуру класичного U-Net (далі — U-генератор) та приймає на вхід комбіноване зображення з шумом. На виході його завданням є відтворення вхідного зображення з додаванням до нього ознак (об'єкта) іншого класу, а також генерування маски, як окремого каналу, що дозволяє визначити положення цього додаткового об'єкта іншого класу на зображенні.

Дискримінатор призначений для встановлення — чи є комбінація зображення та маски згенерованою, чи вона є реальною. На вхід він також приймає зображення і маску як додатковий канал.

За рахунок цих особливостей тренування генератор може трансформувати зображення одного класу у зображення іншого класу, надаючи водночас маску цільового об'єкта як додаткову контрольовану аугментацію даних під час процесу навчання.

На рис. 2 показано етапи процесу перетворення зображень. Спочатку, аналогічно тренуванню, вибирається зображення без класу сегментації, до якого застосовується шум. Ця комбінована структура подається в U-генератор, який намагається додати особливості нового класу та генерує сегментаційну маску цільового об'єкта. Створене зображення може не мати належної якості та відрізнитися від оригіналу, наприклад шумами, тому далі відбувається операція екстрагування згенерованих ознак з отриманого зображення (за допомогою маски) та додавання їх на вхідне зображення (див. рис. 3). Попри це зауваження, запропонований підхід дозволяє забезпечити досить точне позиціонування маски та її вигляду.




Рис. 2. Схема використання моделі



Рис. 3. Приклад агрегації вхідного зображення та маски

Така післяобробка гарантує кращі результати та більшу консистентність у збереженні основного зображення. Це може бути особливо корисно в ситуаціях, як показано на рис. 4: у випадку потреби в аугментації окремих частин зображення, таких як окремі зуби на панорамному знімку, можна використовувати звичайний детектор об'єктів для вирізання необхідних зубів, передавати їх у модель для трансформації та вставляти їх назад на ту саму позицію, як на зображенні, так і в масці сегментації цього зображення. Нове зображення повинно залишатись якнайбільше незмінним (лише зміна в доданому об'єкті) для правильного включення в навколишнє середовище.




Рис. 4. Приклад використання моделі

### Тренування ГЗМ

Для перевірки ефективності описаного вище підходу проведено експеримент щодо тренування генеративної моделі. Вибрано 128 зображень окремих зубів без наявності пломб з набору даних панорамних знімків щелепи [13]. Цим зображенням присвоєно нульовий клас та порожню сегментаційну маску, а відповідні приклади наведено на рис. 5. З того ж набору даних взято 148 зображень зубів з пломбами, яким присвоєно перший клас. Пломби на зубах розмічені бінарною маскою такого самого розміру, де нуль (чорний колір) вказує на відсутність пломби, а один (білий колір) на її наявність, як видно на рис. 6.




Рис. 5. Дані нульового класу




Рис. 6. Дані першого класу

З даних першого класу відібрано 20 зображень зубів (панорамні знімки, з яких взяті ці зображення, використовуються тільки в тестувальних даних) та створено з них тестовий набір для фінальної перевірки моделей (рис. 7). Ці зображення ніяким чином не беруть участь у тренуванні, налаштуванні, валідуванні чи виборі моделей. В основному наборі даних залишається по 128 зображень першого та нульового класів.




Рис. 7. Тестувальні дані

Для тренування моделі U-GAN використані зазначені вище зображення, разом з відповідними сегментаційними масками. Зображення трансформовані до розміру  $128 \times 128$  пікселів перед поданням в модель. Генератором виступала класична архітектура U-Net, а для дискримінатора використовувалася згортоква нейронна мережа. Як функцію втрати вибрано відстань Васерштейна [14].

Для тренування використовувались такі гіперпараметри:

- кількість епох: 300; – розмір пакета: 16;
- оптимізатор (і для генератора, і для дискримінатора): Adam (beta0: 0, beta1: 0,999);

– швидкість навчання (learning rate): 0,0002.

Огляд результатів генерації відбувався кожні 10 епох. Найкращою епохою, визначеною на основі візуальної оцінки згенерованих зображень, виявилася епоха з номером 210.

На рис. 8 показано приклад даних, створених натренованою моделлю та поетапний (зверху вниз) перехід від вхідного зображення нульового класу до зображення першого класу. В першому рядку показано 8 вхідних зображень. Вони подаються до генератора, який трансформує їх в зображення, показані в другому рядку та маски в третьому рядку. Можна побачити, що створене зображення є розмитим та нечітким. Тому із цього зображення вирізається тільки ті фрагменти, які підпадають під маску. Та ці фрагменти накладаються на вхідні зображення, утворюючи фінальний результат, показаний у четвертому рядку.




Рис. 8. Приклад створення зображень

### Тренування сегментаційної моделі

Для оцінки впливу зазначеної аугментації на ефективність тренування моделі проведено експеримент з використанням класичного U-Net для задачі сегментації пломб [15]. Сформовано два різних набори даних для тренування:

- тренування на базових даних: вибрано 128 зображень першого класу, розділено їх на тренувальні та валідаційні в пропорції 80 % та 20 % відповідно (102/26).
- тренування на базових даних з додаванням згенерованих: до тренувального набору з базових даних додано 64 згенерованих зображення. Ці зображення отримані від U-генератора на 210-му етапі в результаті його застосування до наявних зображень нульового класу, після чого кращі зразки відібрано вручну (приклади цих додаткових зображень показані на рис. 9).

Такий підхід дозволив оцінити тільки вплив аугментації на результативність моделі та порівняти її з варіантом, що базується лише на реальних даних. У разі досягнення підвищення точності, цей метод аугментації можна включати в набір гіперпараметрів для навчання: поєднувати його з іншими методами аугментації для досягнення ще кращих результатів.




Рис. 9. Додані дані

В тренування не включались картинки нульового класу, оскільки вони погіршують точність для всіх моделей в обох експериментах.

Проведено 50 тренувань для кожного з двох експериментів, використовуючи різний випадковий стан починаючи від розбиття даних на тренувальну та валідаційну вибірку. Використані такі налаштування для кожного з тренувань:

- модель: U-Net;
- основа моделі: ResNet-34;
- метрика: коефіцієнт Жаккара;
- функція втрат: функція втрат Жаккара;
- кількість епох: 50;
- рання зупинка через 5 епох у випадку не поліпшення валідаційної метрики,
- розмір пакета: 32,
- оптимізатор: Adam,
- швидкість навчання (learning rate): 0,001.

Оцінка моделей проводилася на 20 зображеннях, відведених для тестування. Розподіл тестових оцінок (коефіцієнтів Жаккара), показаний на рис. 10. Середнє значення тестового коефіцієнта Жаккара для експерименту з базовими даними склало 94,2, а для експерименту з базовими та згенерованими даними 96,1. Різниця складає майже 2 відсотки. Ці результати свідчать про те, що згенеровані таким чином дані дійсно допомагають поліпшити результати тренування сегментаційних моделей.




Рис. 10. Розподіл оцінок сегментації на тестових даних

## Висновки

Розроблено новий підхід для перетворення зображень з одного класу в інший, що включає в себе створення та визначення позиції маски цього класу. За рахунок розробленого алгоритму з'єднання згенерованої частини даних (що відповідає за ознаки класу), задачею ГЗМ було не ідеальне відтворення вхідного зображення, а акцентування на правильності створення та позиціонування ознак об'єкта іншого класу та його маски.

Запропонований підхід призначений для вирішення проблеми обмеженої кількості тренувальних даних та сильного дисбалансу класів. Ефективність підходу перевірено на задачі сегментації зубних пломб на панорамних рентгенівських знімках. Результати показали покращення коефіцієнта Жаккара моделі сегментації майже на 2 %, що підтверджує ефективність такого рішення.

Запропонований метод можна використовувати як окремо, так і в комбінації з іншими методами аугментації. До прикладу, можна на початку збільшити кількість прикладів міноритарного класу за допомогою розробленого підходу, а в подальшому використати традиційні аугментації (повороти, віддзеркалення, зміну контрастності тощо).

Подальшими кроками дослідження може бути впровадження під час тренування методів автоматичної оцінки результатів моделі та додаткових штрафів за відхилення генерації моделі від вхідних даних для автоматизації процесу вибору кращої моделі та згенерованих прикладів.

## СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

- [1] P. Dhariwal and A. Q. Nichol, "Diffusion Models Beat GANs on Image Synthesis," in *Advances in Neural Information Processing Systems*, 2021. [Online]. Available: <https://openreview.net/forum?id=AAWuCVzaVt>. Accessed: January 30, 2024.
- [2] V. Sandfort, K. Yan, P.J. Pickhardt, et al., "Data augmentation using generative adversarial networks (CycleGAN) to improve generalizability in CT segmentation tasks," *Sci Rep*, vol. 9, Article no. 16884, 2019. <https://doi.org/10.1038/s41598-019-52737-x>.
- [3] H. Mansourifar, L. Chen and W. Shi, "Virtual Big Data for GAN Based Data Augmentation," *2019 IEEE International Conference on Big Data (Big Data)*, Los Angeles, CA, USA, 2019, pp. 1478-1487, <https://doi.org/10.1109/BigData47090.2019.9006268>.
- [4] A. Sauer, K. Schwarz, and A. Geiger, "StyleGAN-XL: Scaling StyleGAN to Large Diverse Datasets," in *ACM SIGGRAPH 2022 Conference Proceedings (SIGGRAPH '22)*, Association for Computing Machinery, New York, NY, USA, 2022, Article 49, pp. 1–10. <https://doi.org/10.1145/3528233.3530738>.
- [5] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," *Computer Science Department and BIOSS Centre for Biological Signalling Studies*, University of Freiburg, Germany, 2015. [Online].

Available: <https://arxiv.org/pdf/1505.04597.pdf> . Accessed: January 30, 2024.

[6] R. Gulakala, B. Markert, and M. Stoffel, "Generative adversarial network based data augmentation for CNN based detection of Covid-19," *Sci Rep*, vol. 12, Article no. 19186, 2022. <https://doi.org/10.1038/s41598-022-23692-x> .

[7] X. Chen, et al., "Generative Adversarial U-Net for Domain-free Medical Image Augmentation," in *arXiv e-prints*, 2021. [Online]. Available: <https://arxiv.org/pdf/2101.04793.pdf> . Accessed: January 30, 2024.

[8] E. Yildiz, et al., "Generative Adversarial Network Based Automatic Segmentation of Corneal Subbasal Nerves on In Vivo Confocal Microscopy Images," *Trans. Vis. Sci. Tech.*, vol. 10, no. 6, Article 33, 2021. <https://doi.org/10.1167/tvst.10.6.33> .

[9] T. Neff, C. Payer, D. Stern, and M. Urschler, "Generative Adversarial Network based Synthesis for Supervised Medical Image Segmentation," *OAGM & ARW Joint Workshop*, 2017. <https://doi.org/10.3217/978-3-85125-524-9-30> .

[10] C. Bowles, et al., "GAN Augmentation: Augmenting Training Data using Generative Adversarial Networks," in *arXiv e-prints*, 2018. [Online]. Available: <https://arxiv.org/abs/1810.10863> . Accessed: January 30, 2024.

[11] V. Sushko, D. Zhang, J. Gall, and A. Khoreva, "One-Shot Synthesis of Images and Segmentation Masks," in *arXiv e-prints*, 2022. [Online]. Available: <https://arxiv.org/abs/2209.07547> . Accessed: January 30, 2024.

[12] T. Malygina, E. Ericheva, and I. Drogen, "Data Augmentation with GAN: Improving Chest X-Ray Pathologies Prediction on Class-Imbalanced Cases," in *W. van der Aalst et al. (Eds.), Analysis of Images, Social Networks and Texts, AIST 2019, Lecture Notes in Computer Science*, vol. 11832, Springer, Cham, 2019. <https://doi.org/10.1007/978-3-030-37334-429> .

[13] H. Abdi, S. Kasaei, and M. Mehdizadeh, "Automatic segmentation of mandible in panoramic x-ray," *J. Med. Imaging (Bellingham)*, vol. 2, no. 4, 044003, 2015. [Online]. Available: [https://www.academia.edu/36038975/PreProcessing\\_of\\_Dental\\_X-Ray\\_Images\\_Using\\_Adaptive\\_Histogram\\_Equalization\\_Method](https://www.academia.edu/36038975/PreProcessing_of_Dental_X-Ray_Images_Using_Adaptive_Histogram_Equalization_Method). Accessed: January 30, 2024.

[14] Я. О. Ісаєнков, і О. Б. Мокін, «Аналіз генеративних моделей глибокого навчання та особливостей їх реалізації на прикладі WGAN», *Вісник Вінницького політехнічного інституту*, № 1, с. 82-94, 2022. <https://doi.org/10.31649/1997-9266-2022-160-1-82-94> .

[15] О. В. Коменчук, і О. Б. Мокін, «Аналіз методів передоброблення панорамних стоматологічних рентгенівських знімків для задач сегментації зображень», *Вісник Вінницького політехнічного інституту*, № 5, с. 41-49, 2023. <https://doi.org/10.31649/1997-9266-2023-170-5-41-49> .

Рекомендована кафедрою системного аналізу та інформаційних технологій ВНТУ

Стаття надійшла до редакції 13.02.2024

**Ісаєнков Ярослав Олександрович** — аспірант кафедри системного аналізу та інформаційних технологій, e-mail: oiuygl@gmail.com ;

**Мокін Олександр Борисович** — д-р техн. наук, професор, професор кафедри системного аналізу та інформаційних технологій, e-mail: abmokin@gmail.com .

Вінницький національний технічний університет, Вінниця

**Ya. O. Isaienkov<sup>1</sup>**  
**O. B. Mokin<sup>1</sup>**

## Target Class Transformation for Segmentation Task Using U-GAN

<sup>1</sup>Vinnitsia National Technical University

The paper presents a review of modern generative adversarial models for data augmentation, focusing on research, aimed at creating images and their corresponding segmentation masks. This task is particularly useful in cases where data is insufficient, hard to access, has confidential nature, or where labeling requires significant resources. The paper is aimed at the task of augmenting the minority class by transforming an image from another class and creating a segmentation mask. New approach is proposed for the simultaneous generation of the image and segmentation mask, using a generative adversarial network with U-Net generator. This generator takes an image of one class and noise, which is fed as an additional image channel. The generator tries to create an image of another class, minimizing changes in the original image and adding features of another along with the segmentation mask of the new class. The discriminator then determines whether the picture-mask pair is real or generated. The algorithm that applies only those changes of the generated image that are indicated by the created segmentation mask used to preserve the original appearance of the input image with minimal changes. This technique allows to obtain an image with features of the new class with minimal changes. The practical implementation of the proposed approach was conducted on a dataset of panoramic dental X-rays, based on which a set of individual teeth was created, some with fillings and some without. The experimental data set included 128 teeth without fillings and 128 with fillings. The GAN is trained to transform images without fillings into similar ones with fillings using all input images. Two experiments of 50 simulations each with different random states were conducted for training the segmentation model U-Net with ResNet-34 backbone to check the effectiveness of this augmentation. The first experiment used only real data for training, while the second included 64 additional images and masks created by the generator based on existing zero-class images. The average Jaccard score among all simulations for the first and second experiments were respectively 94.2 and 96.1. This result indicates that data generated using the proposed augmentation helps improve the quality of segmentation models and this approach can be combined with other augmentation techniques.

**Keywords:** augmentation, data generation, generative adversarial network, segmentation, deep learning, GAN, U-GAN, U-generator.

**Isaienkov Yaroslav O.** — Post-Graduate Student of the Chair of System Analysis and Information Technologies, e-mail: oiuygl@gmail.com ;

**Mokin Oleksandr B.** — Dr. Sc. (Eng.), Professor, Professor of the Chair of System Analysis and Information Technologies, e-mail: abmokin@gmail.com