

УДК 519.6+004.891.3+616-018

## АУГМЕНТАЦИЯ ОБУЧАЮЩЕЙ ВЫБОРКИ ГИСТОЛОГИЧЕСКИХ ИЗОБРАЖЕНИЙ АДВЕРСАТИВНЫМИ АТАКАМИ

© 2023 г. Н. Д. Локшин<sup>a,\*</sup> (ORCID: 0000-0001-7777-7035),  
 А. В. Хвостиков<sup>a,\*\*</sup> (ORCID: 0000-0002-4217-7141),  
 А. С. Крылов<sup>a,\*\*\*</sup> (ORCID: 0000-0001-9910-4501)

<sup>a</sup> Московский государственный университет имени М.В. Ломоносова,  
 119991 Москва, ГСП-1, Ленинские горы, д. 1, Россия

\*E-mail: lockshin1999@mail.ru

\*\*E-mail: khvostikov@cs.msu.ru

\*\*\*E-mail: kryl@cs.msu.ru

Поступила в редакцию 09.01.2023 г.

После доработки 15.01.2023 г.

Принята к публикации 20.01.2023 г.

В работе рассматривается задача аугментации выборки гистологических изображений адверсативными атаками для повышения устойчивости нейросетевых классификаторов, обученных на аугментированной выборке, к адверсативным атакам. В последние годы нейросетевые методы стремительно развивались, новые нейросетевые методы показывают впечатляющие результаты, однако они подвергаются так называемым адверсативным атакам — то есть совершают неверные предсказания на входах, получающихся в результате наложения на изображение малого шума. Из-за этого надежность нейросетевых методов до сих пор является актуальной областью изучения. В этой статье мы представляем и сравниваем между собой различные методы аугментации обучающей выборки, позволяющие повысить устойчивость нейросетевых классификаторов гистологических изображений к адверсативным атакам. Для этого мы предлагаем добавлять в обучающую выборку адверсативные атаки, полученные несколькими актуальными методами.

DOI: 10.31857/S0132347423030020, EDN: DEEBYB

### 1. ВВЕДЕНИЕ

Некоторые модели машинного обучения, в частности нейронные сети, часто подвергаются *адверсативным атакам* — то есть неверно классифицируют входы, получающиеся в результате наложения на изображение малого шума [1–4] (рис. 1). На данный момент имеется большое количе-

ство способов генерации таких атак, а также и методов защиты от них [1, 7, 8]. Большинство способов защиты от адверсативных атак либо предусматривают изменение структуры исходной модели предсказания, например, *защитная дистилляция* нейросетей [8], либо строят предположения о возможных атаках.




Рис. 1. Пример адверсативной атаки на модель ResNet50 [5] на изображение из набора данных NCT-CRC-HE-100K [6].

Самым эффективным методом генерации адверсативных возмущений на данный момент является метод *AdvGAN* [9]. Основные преимущества AdvGAN перед другими способами генерации адверсативных атак заключаются в более низкой степени искажения исходных изображений при совершении атаки и более высокой вероятности совершить атаку на изображения успешно. Данный метод заключается в *генеративно-сопоставительном* [10] обучении нейросети, которая после этапа обучения способна генерировать адверсативные возмущения по переданным на вход изображениям.

В данной работе на основе [1, 3, 9, 11, 12] предлагается метод повышения устойчивости нейросетевых классификаторов гистологических изображений к адверсативным атакам.

## 2. АДВЕРСАТИВНЫЕ АТАКИ

В данной работе рассматривается 5 алгоритмов генерации адверсативных атак: *Fast Gradient Sign Method* (FGSM) [1], *Carlini and Wagner* (C&W) [3], *AdvGan* [9], *Projected Gradient Descent* (PGD) [11] и *Decoupled Direction and Norm* (DDN) [13].

Алгоритмы генерации адверсативных атак делятся на White-Box и Black-Box. White-Box-алгоритмы принимают на вход, помимо изображения, по которому необходимо построить адверсативную атаку, обученную нейросеть. Black-Box-алгоритмы принимают на вход только изображение. Все алгоритмы, рассматриваемые в данной статье, являются White-Box.

### Fast Gradient Sign Method

Имея на входе изображение  $I$  с меткой класса  $y$ , функцию потерь  $J$ , обученный классификатор  $C$ , размер шага  $\epsilon$ , адверсативное изображение вычисляется следующим образом:

$$\tilde{I} = I + \epsilon \cdot \text{sign} \nabla J(C, I, y) \quad (2.1)$$

В данном алгоритме число  $\epsilon$  является гиперпараметром. Как правило,  $\epsilon$  выбирается достаточно малым, чтобы накладываемое на изображение возмущение было слабо заметным. В данной работе  $\epsilon = 0.07$ .

### Projected Gradient Descent

Имея на входе изображение  $I$  с меткой класса  $y$ , функцию потерь  $J$ , обученный классификатор  $C$ , размер шага  $\alpha$  и количество итераций  $K$ , для  $k = 1 \dots K$  совершается вычисление:

$$I_{k+1} = \prod_{I+S} (I_k + \alpha \cdot \text{sign}(\nabla_{I_k} J(C, I_k, c))) \quad (2.2)$$

$I_0$  принимается равным  $I$ . На выходе алгоритма имеем адверсативное изображение  $I_K$ . В данной работе  $\alpha = 3 \times 10^{-3}$ , количество шагов равно 100,  $S - I_\infty$ -сфера вокруг изображения  $I$  с радиусом 0.01.

### Decoupled Direction and Norm

Имея на входе изображение  $I$  с меткой класса  $y$ , функцию потерь  $J$ , обученный классификатор  $C$ , размер шага  $\alpha$ , шаг обновления радиуса  $\gamma$  и количество итераций  $K$ , для  $k = 1 \dots K$  совершаются следующие действия:

1. Вычисление градиента:

$$g \leftarrow \nabla J_{\tilde{I}_{k-1}}(C, \tilde{I}_{k-1}, y) \quad (2.3)$$

2. Нормирование и умножение на размер шага:

$$g \leftarrow \alpha \frac{g}{\|g\|_2} \quad (2.4)$$

3. Обновление адверсативного возмущения:

$$\sigma_k = \sigma_{k-1} + g \quad (2.5)$$

Возмущение  $\sigma_0$  принимается равным 0.

4. Проекция адверсативного изображения  $\tilde{I}_{k-1} + \sigma_k$  на  $\epsilon_k$ -сферу вокруг исходного изображения  $I$ .  $\epsilon_k$  берется равным  $(1 + \gamma)\epsilon_{k-1}$ , если  $\tilde{I}_{k-1}$  успешно нарушает работу  $C$ , либо  $(1 - \gamma)\epsilon_{k-1}$ , если иначе:

$$\tilde{I}_k = \tilde{I}_{k-1} + \epsilon_k \frac{\sigma_k}{\|\sigma_k\|_2} \quad (2.6)$$

5. Клиппирование значений, выходящих за допустимые границы:  $\tilde{I}_k: \tilde{I}_k \leftarrow \text{clip}(\tilde{I}_k, 0, 1)$ .

В конце итераций на выход подается такое  $\tilde{I}_k$ , которое успешно нарушает работу  $C$  и имеет наименьшую  $l_2$ -норму.

### Carlini and Wagner

Имея на входе изображение  $I$  с меткой класса  $y$  и обученный нейросетевой классификатор  $C$ , адверсативная атака выполняется путем решения задачи оптимизации:

$$\begin{aligned} &\text{minimize } \|\sigma\|_2 - \epsilon \cdot f(I + \sigma) \\ &\text{suchthat } I + \sigma \in [0, 1]^n, \end{aligned} \quad (2.7)$$




Рис. 2. Примеры изображений из набора NCT-CRC-NE-100K [6, 14].

где функция  $f$  подобрана таким образом, что  $C(I + \sigma) = c$  тогда и только тогда, когда  $f(x + \sigma) \leq 0$ . В данном эксперименте,

$$f(I + \sigma) = \max\left(\max_{i \neq y} (Z(I + \sigma)_i) - Z(I)_y, 0\right), \quad (2.8)$$

где  $Z(I)$  – ненормированный выход классификатора  $C$  с принятием на вход  $I$ . Данная функция признана самой эффективной из возможных в оригинальной статье. Оптимальное значение константы  $\epsilon$  таково что оно наименьшее, для которого  $f(I + \sigma) \leq 0$ . Чтобы найти  $\epsilon$ , совершается 20 шагов бинарного поиска, где на каждом шаге находится решение  $I + \sigma$  решением задачи оптимизации 2.7 методом градиентного спуска. В данной работе количество шагов градиентного спуска равно 100 с шагом 0.01.

#### AdvGan

Данный алгоритм строит адверсативную атаку путем обучения генеративно-состязательной сети (GAN). Во время обучения генератор  $G(z)$  минимизирует следующий функционал:

$$l = \gamma l_{nce} + \theta l_{GAN} + \zeta l_{threshold}, \quad (2.9)$$

где  $l_{nce}$  – это обратный функционал кросс-энтропии:

$$l_{nce} = \frac{1}{l_{ce}}, \quad (2.10)$$

$$l_{ce} = -\frac{1}{N} \sum_{n=1}^N \log \frac{\exp(x_{n,y_n})}{\sum_{c=1}^{N_c} \exp(x_{n,c})}, \quad (2.11)$$

$l_{GAN}$  – это функционал, оптимизируемый в рамках генеративно-состязательной сети:

$$l_{GAN} = \mathbb{E}_{I \sim p_{data}(I)} \log D(I) + \mathbb{E}_{I \sim p_{adversarial}(I)} \log(1 - D(I + aG(z))), \quad (2.12)$$

где  $G(z)$  имеет на выходе изображение,  $D(I)$  имеет на выходе вероятность того, что изображение  $I$  – настоящее.  $l_{threshold}$  задан следующим образом:

$$l_{threshold} = \sum_{x=1}^W \sum_{y=1}^H \sum_{z=1}^C \max(|I_{x,y,z}| - thr, 0)^2, \quad (2.13)$$

где  $I_{x,y,z}$  – значения пикселя изображения  $I$  в координатах  $(x, y, z)$ . В данном эксперименте значение  $thr$  равно 0.25. Коэффициенты  $\gamma$ ,  $\theta$  и  $\zeta$  были эмпирически подобраны и равны 10, 1, 1 соответственно.

**Таблица 1.** Результаты тестирования классификаторов, имеющих структуру ResNet50. В левой колонке приведены обучающие выборки: 18K – исходная обучающая выборка, 36K – исходная обучающая выборка, аугментированная 18000 синтетическими изображениями, сгенерированными StyleGan2, 72K – набор 36K, аугментированный  $AdvGan_{a=1}$ , 216K – набор 36K, аугментированный  $AdvGan_{a=1}$ , FGSM, DDN, PGD, C&W. Названия алгоритмов генерации адверсативных атак в столбцах обозначают адверсативную атаку, примененную к каждому изображению в тестовой выборке

| Обуч. выборка | Точность на тестовой выборке с применением различных видов атак |       |       |       |       |                  |                |                |
|---------------|-----------------------------------------------------------------|-------|-------|-------|-------|------------------|----------------|----------------|
|               | No attack                                                       | FGSM  | DDN   | PGD   | C&W   | $AdvGan_{a=0.5}$ | $AdvGan_{a=1}$ | $AdvGan_{a=2}$ |
| 18K           | 99.49                                                           | 19.43 | 0     | 0.01  | 0     | 96.22            | 69.57          | 44.60          |
| 36K           | 99.37                                                           | 36.69 | 97.76 | 1.25  | 95.60 | 95.99            | 72.73          | 46.64          |
| 72K           | 99.23                                                           | 53.24 | 98.30 | 8.85  | 97.73 | 99.36            | 99.32          | 95.36          |
| 216K          | 98.89                                                           | 84.16 | 98.61 | 72.33 | 98.46 | 98.78            | 98.47          | 94.82          |

### 3. ПОСТАНОВКА ЗАДАЧИ

В качестве входных данных имеется 22 500 размеченных изображений – подмножество набора *NCT-CRC-HE-100K* [6, 4]. Изображения являются непересекающимися участками больших гистологических изображений, содержащих злокачественные новообразования толстого кишечника а также здоровые ткани, окрашенные гематоксилин-эозином. Подмножество набора данных выбрано для уменьшения временных затрат на эксперименты и обучение нейросетевых методов. Изображения имеют размерности  $224 \times 224 \times 3$ . Данные равномерно размечены на 9 классов тканей: *adipose (ADI)*, *background (BACK)*, *debris (DEB)*, *lymphocytes (LYM)*, *mucus (MUC)*, *smooth muscle (MUS)*, *normal colon mucosa (NORM)*, *cancer-associated stroma (STR)*, *colorectal adenocarcinoma epithelium (TUM)*. Примеры изображений для каждого класса приведены на рис. 2.

Приведенный набор разбит на тренировочную выборку, содержащую 18000 изображений, и тестовую, содержащую 4500 изображений. Требуется исследовать и реализовать методы аугментации данного набора данных различными адверсативными атаками и сравнить качество различных нейросетевых классификаторов на скрытых выборках, также аугментированных адверсативными атаками. Термин “скрытая” выборка означает, что изображения из этой выборки не принадлежат обучающей выборке.

### 4. ПРЕДЛАГАЕМЫЙ МЕТОД

В данной работе предлагается рассматривать несколько наборов данных для обучения, аугментированных различными наборами адверсативных атак, а именно:

- Исходная обучающая выборка, состоящая из 18000 гистологических изображений;
- Обучающая выборка, состоящая из 18000 исходных гистологических изображений, и 18000 синтетических изображений, сгенерированных хорошо известным алгоритмом StyleGAN2 – всего 36000 изображений;
- 36000 изображений из предыдущего пункта, аугментированных 36000 адверсативными атаками AdvGan (т.е. применение AdvGan к каждому из 36000 изображений в обучающей выборке с последующим добавлением результата в обучающую выборку) – всего 72000 изображений;
- 216000 изображений в результате аугментации алгоритмами DDN, C&W, FGSM, PGD и AdvGan. Каждый из перечисленных алгоритмов был применен к каждому из 36000 изображений с последующим добавлением результата в обучающую выборку.

На каждой обучающей выборке был обучен нейросетевой классификатор имеющий архитектуру *ResNet50* [5], в итоговом сравнении участвует 4 нейросетевых классификатора, имеющих оди-

наковую структуру, но обученных на разных наборах данных. Для тестирования используются следующие скрытые наборы данных:

- Исходная тестовая выборка, состоящая из 4500 гистологических изображений;
- Тестовая выборка, состоящая из 4500 исходных гистологических изображений с применением FGSM [1] с параметром  $\epsilon = 0.1$ ;
- Тестовая выборка, состоящая из 4500 исходных гистологических изображений с применением C&W [3];
- Тестовая выборка, состоящая из 4500 исходных гистологических изображений с применением PGD [11];
- Тестовая выборка, состоящая из 4500 исходных гистологических изображений с применением DDN [13];
- Тестовая выборка, состоящая из 4500 исходных гистологических изображений с применением AdvGan с параметром  $a = 0.5$ ;
- Тестовая выборка, состоящая из 4500 исходных гистологических изображений с применением AdvGan с параметром  $a = 1$ ;
- Тестовая выборка, состоящая из 4500 исходных гистологических изображений с применением AdvGan с параметром  $a = 2$ .

## 5. АНАЛИЗ ПОЛУЧЕННЫХ РЕЗУЛЬТАТОВ

Результаты экспериментов приведены в табл. 1. Предложенный метод аугментации данных существенно повысил устойчивость нейросетевого классификатора ResNet50 к адверсативным атакам. Тем не менее, даже при увеличении объема обучающей выборки в 12 раз вышеприведенным методом точность классификатора на скрытой выборке без применения к ней адверсативных атак изменяется незначительно.

## 6. ЗАКЛЮЧЕНИЕ

В данной работе был предложен и реализован метод аугментации обучающей выборки адверсативными атаками для обучения нейросетевых классификаторов. В случае, когда архитектуры классификатора, использовавшегося для генерации адверсативных атак, и тестового классификатора совпадали, было продемонстрировано повышение устойчивости против ряда адверсативных атак. Для обучения моделей использовался вычислительный кластер с 4x Nvidia RTX A6000 факультета вычислительной математики и киберне-

тики Московского государственного университета имени М.В. Ломоносова.

## БЛАГОДАРНОСТИ

Исследования выполнены при финансовой поддержке Российского научного фонда в рамках научного проекта 22-21-00081.

## СПИСОК ЛИТЕРАТУРЫ

1. Goodfellow I.J., Shlens J., Szegedy Ch. Explaining and harnessing adversarial examples // arXiv preprint arXiv:1412.6572, 2014
2. Su Jiawei, Vargas Danilo Vasconcellos, Sakurai Kouichi. One pixel attack for fooling deep neural networks // IEEE Transactions on Evolutionary Computation. 2019. № 5. С. 828–841.
3. Carlini N., Wagner D. Towards evaluating the robustness of neural networks // IEEE Symposium on Security and Privacy (SP). 2017. P. 39–57.
4. Moosavi-Dezfooli, Seyed-Mohsen, Fawzi Alhussein, Frossard Pascal. Deepfool: a simple and accurate method to fool deep neural networks // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016. P. 2574–2582.
5. He Kaiming, Zhang Xiangyu, Ren Shaoqing, Sun Jian. Deep residual Learning for Image Recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016. P. 770–778.
6. Kather J.N., Halama N., Marx A. 100000 histological images of human colorectal cancer and healthy tissue // Zenodo10, 2018.
7. Liang Bin, Li Hongcheng, Su Miaoqiang, Li Xirong, Shi Wenchang, Wang Xiaofeng. Detecting adversarial image examples in deep neural networks with adaptive noise reduction // IEEE Transactions on Dependable and Secure Computing. 2018. № 1. P. 72–85.
8. Papernot N., McDaniel P., Wu Xi, Jha Somesh, Swami Ananthram. Distillation as a defense to adversarial perturbations against deep neural networks // IEEE Symposium on Security and Privacy (SP), 2016. P. 582–597.
9. Xiao Chaowei, Li Bo, Zhu Jun-Yan, He Warren, Liu Mingyan, Song Dawn. Generating adversarial examples with adversarial networks // arXiv preprint arXiv:1801.02610, 2018.
10. Goodfellow I., Pouget-Abadie J., Mirza Mehdi, Xu Bing, Warde-Farley D., Ozair Sherjil, Courville A., Bengio Yoshua. Generative adversarial nets // Advances in Neural Information Processing Systems, 2014.
11. Madry A., Makelov A., Schmidt L., Tsipras D., Vladu A. Towards deep learning models resistant to adversarial attacks // arXiv preprint arXiv:1706.06083, 2017.

12. *Karras Tero, Laine Samuli, Aittala Miika, Hellsten Janne, Lehtinen Jaakko, Aila Timo.* Analyzing and improving the image quality of stylegan // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020. P. 8110–8119.
13. *Rony J., Hafemann L.G., Oliveira L.S., Ayed Ismail Ben, Sabourin R., Granger E.* Decoupling direction and norm for efficient gradient-based l2 adversarial attacks and defenses // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019. P. 4322–4330.
14. *Khvostikov A., Krylov A., Mikhailov I., Malkov P., Danilova N.* Tissue Type Recognition in Whole Slide Histological Images. 2021.