

## НОРМАЛІЗАЦІЯ ЗОБРАЖЕНЬ ЗА ДОПОМОГОЮ ГЕНЕРАТИВНИХ ЗМАГАЛЬНИХ МЕРЕЖ

Стребков Г. С., Кіріченко І. К.

Науковий керівник – д.т.н., проф. Путятін Є.П.

Харківський національний університет радіоелектроніки  
(61166, Харків, пр. Науки, 14, каф. Інформатики, тел. (057) 702-14-19)  
e-mail: heorhii.strebkov@nure.ua, igor.kirichenko.07@gmail.com

The problem of recognition and reconstruction of damaged or low-quality images was solved. The problem of generating potential prototype or corrected images was solved. The algorithm of generative adversarial networks functioning was discussed, researched and described. Potential use cases and algorithm purposes in the field of image normalization were proposed. In practice, dataset serves the initial training data for the discriminator. Training the discriminator involves presenting it with samples from dataset, until it reaches certain level of accuracy. Typically, the generator is seeded with a randomized input that is sampled from a predefined latent space. Backpropagation is applied in both networks so that the generator produces better images, while the discriminator becomes more skilled at flagging synthetic images.

Генеративні змагальні мережі є відносно новим структурним середовищем оцінювання генеративних моделей за допомогою змагального процесу, в якому відбувається одночасне тренування двох мереж: генеративної мережі А, яка відповідає за зчитування, розміщення зразків даних відносно один одного, та дискримінаційної мережі В, метою якої є оцінка вірогідності такого результату, що передбачає надходження оцінюваного зразка з даних для навчання, а не з мережі А.


Процедура навчання А ставить за мету досягнення такого рівня реконструкції зображення, за якого мережа В припуститься помилки. Взаємодія мереж такого структурного середовища є практичною реалізацією мінімаксної стратегії гри двох гравців. Для довільних значень функцій А і В існує унікальне спільне рішення: А реконструює розподіл навчальних даних, а результат В дорівнює 0,5 у кожному окремому випадку. У тому випадку, якщо А і В задаються багатопарним перцептроном, навчання всієї системи може виконуватися за допомогою зворотного поширення. Потенціал структурного середовища можна виразити кількісною та якісною оцінкою згенерованих зразків [1].

Найпростіша реалізація структурного середовища для моделювання змагальної мережі полягає в використанні для обох мереж багатопарних перцептронів. Для вивчення розподілу  $P_g$  по даних  $x$  змінні величини шуму, який вплинув на зображення до його впровадження до мережі, можна зазначити як  $P_z(z)$ , поступлення до простору даних позначити як  $A(z; \theta_g)$ , де  $A$  є диференційованою функцією, представленою

багатошаровим перцептроном із параметрами  $\theta_g$ . Другий багатошаровий перцептрон, на виході якого модель отримуватиме одиничний вектор, позначимо як  $B(x; \theta_d)$ . Величина  $B(x)$  є вірогідністю того, що зразок  $x$  надійшов із даних, а не з  $P_g$ . Навчання мережі  $B$  спрямовано на максимізацію ймовірності правильного маркування як навчальних зразків, так і тих, які надійшли з мережі  $A$ . Одночасно з цим відбувається навчання мережі  $G$ , спрямоване на мінімізацію  $\log(1 - B(A(z)))$ . Мережі  $B$  і  $A$  виконують ролі гравців в мінімакській грі двох гравців, функція цінностей якої виражається за допомогою формули:

$$\min_A \max_B V(B, A) = E_{x \sim p_{data}(x)} [\log B(x)] + E_{z \sim p_z(z)} [\log(1 - B(A(z)))] .$$

За допомогою алгоритмів, які використовують генеративні змагальні мережі, вирішують задачі single image super-resolution (SISR — відновлення зображення з високою розподільною якістю [HR] із зображення з низкою розподільною якістю [LR]), які привертають увагу дедалі більшого числа дослідницьких спільнот та компаній, що займаються розробкою систем штучного інтелекту [3].



Генеративні змагальні мережі допомагають в генерації та прототипуванні нових зразків конструкторських рішень в сфері ергономіки та дизайну [4]. Універсальність та глибокі можливості конфігурації генеративно-змагальних мереж забезпечують широкий спектр використання цієї технології.

### Список використаних джерел:

8. Krizhevsky, A. and Hinton, G. (2009). Learning multiple layers of features from tiny images. Technical report, University of Toronto
9. Gregor, K., Danihelka, I., Mnih, A., Blundell, C., and Wierstra, D. (2014). Deep autoregressive networks. In ICML'2014.
10. Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., Courville, A.C.: Improved training of wasserstein gans. In: NIPS. (2017)
11. A. Achille and S. Soatto. On the emergence of invariance and disentangling in deep representations. CoRR, abs/1706.01350, 2017.