


МАТЕМАТИЧНІ МЕТОДИ ВІДНОВЛЕННЯ З ПСОВАНИХ ЗОБРАЖЕНЬ

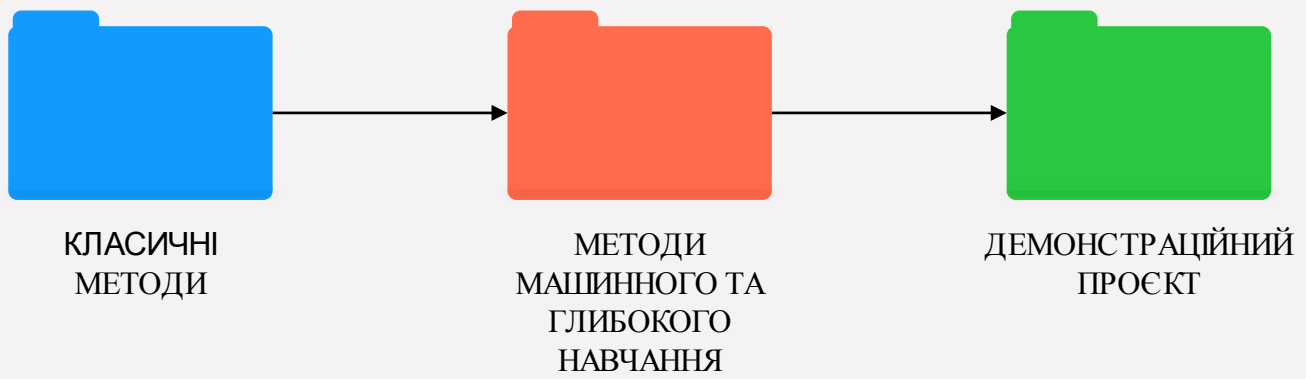


Актуальність

1. Застосування цифрових зображень у галузях критичної інфраструктури

2. Втрата даних

3. Попит на автоматизацію й підвищення якості візуального контенту



Класичні Методи

Просторова фільтрація

Ідея: використання згортки з різними функціями-ядрами (фільтрами) задля зміни характеристик зображення.

Методи: арифметичне середнє, медіанний фільтр, гаусів фільтр, Лапласіан-фільтр.




Рис. 1. Згортка. Оригінальне зображення взяте з wiki.cloudfactory.com


Класичні Методи

Частотна фільтрація

Ідея: використання перетворення Фур'є (FFT), модифікація частотного спектру зображення, зворотне перетворення Фур'є (IFFT);

Методи: фільтр Баттерворта, фільтр Вінера;

Переваги: зменшення обчислювальної складності



Класичні Методи

Вейвлет-перетворення

Ідея: розширення можливостей перетворення Фур'є, декомпозиція зображення, мультирезольційний аналіз.

Методи: метод знешумлення Донохо-Джонстона

Інші практичні використання: підвищення роздільної здатності, виявлення контурів.




Рис. 3. Дворівнева декомпозиція зображення з допомогою вейвлет-перетворення

Класичні Методи

Регуляризація

Ідея: постановка завдання відновлення зображення як оптимізаційної задачі, введення регуляризатора й відомої інформації про оригінальне зображення.

Методи: регуляризація за Тихоновим, регуляризація максимальної ентропії, регуляризація повної дисперсії.



Рис. 4. Відновлення зображення спотвореного розмиттям у русі й білим шумом з $\text{SNR}=30$ дБ регуляризацією повної дисперсії.

АВТОКОДУВАЛЬНИКИ



Автокодувальник - нейронна мережа з енкодер-декодер архітектурою, метою якої є реконструкція вхідних даних, за якої похибка між вхідними та вихідними значеннями мінімізується.

Використання: генерація, інпейнтинг, збільшення роздільної здатності, знешумлення зображень та інші.

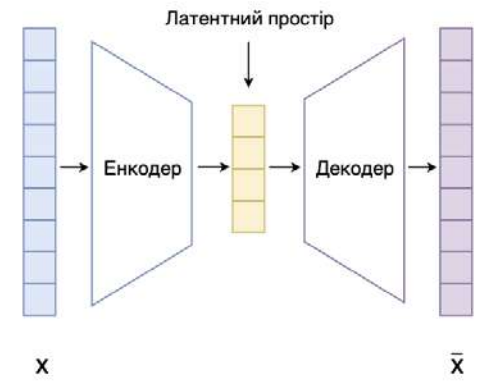


Рис. 5. Архітектура базового автокодувальника

Згорткові нейронні мережі

Згорткові нейронні мережі (CNN) - послідовність

згорткових шарів, які зазвичай супроводжуються, зменшенням розмірності (pooling) та декодером.

Використання: шумозаглушення, збільшення роздільної здатності, відновлення втрачених фрагментів зображення.




Рис. 6. Архітектура базової CNN. Оригінальне зображення взяте з zilliz.com

Генеративні змагальні мережі



Генеративні навчальні мережі (GAN) - клас моделей глибокого навчання, що складаються з двох нейронних мереж: генератора й дискримінатора, які навчаються у змагальному процесі.

Використання: генерація нових зображень, інпейнтинг.

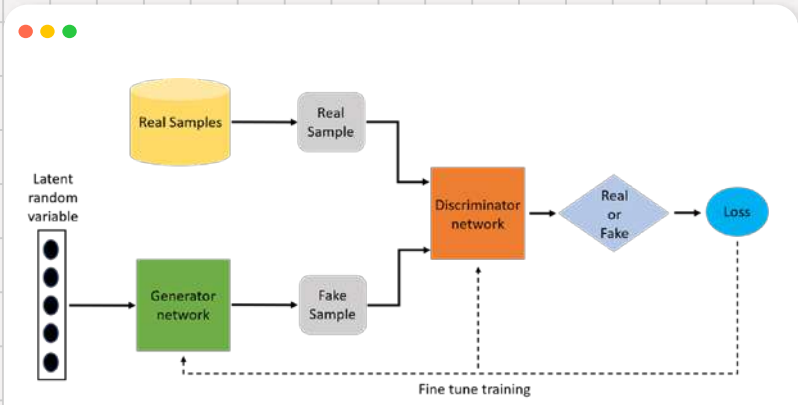


Рис. 7. Архітектура базової GAN. Оригінальне зображення взяте з arxiv.org


ДАТАСЕТ



Для виконання демонстраційного проекту було обрано **CIFAR-10**, що нерідко використовується для тренування класифікаційних моделей.


Розмірність: 60000 зображень розміром 32x32 пікселі.

ПЛАН



1. Навчання змагального автоенкодера (adversarial autoencoder) на вибірці з CIFAR-10;
2. Оцінка ефективності моделі за PSNR, SSIM та візуальним результатом;
3. Розширення моделі, введення U-Net архітектури та додаткової функції втрат: перцептивної;
4. Порівняння результатів.

АРХІТЕКТУРА



РЕЗУЛЬТАТИ



Табл. 4.1: Проміжні значення описових метрик моделі

Епоха	Втрати генератора	PSNR	SSIM
1	0.6605	12.33	0.1161
700	0.1225	18.80	0.4652
1500	0.1043	19.92	0.5546






Табл. 4.2: Проміжні значення описових метрик модифікованої моделі

Епоха	Втрати генератора	PSNR	SSIM	Перцептивна втрата
1	0.6305	12.86	0.1161	4.8475
250	0.2006	23.16	0.8249	3.0872
500	0.1606	25.71	0.8843	2.2180

РЕЗУЛЬТАТИ





- розглянуто теоретичні засади обробки цифрових зображень математичними методами;
- розглянуто методи усунення шуму й розмиття;
- розроблено модель глибокого навчання для генеративного заповнення зображень з пошкодженими ділянками
- За подальшого навчання, розширення вибірки навчальних даних, побудована модель може використовуватись для генеративного заповнення різного виду пошкоджень у зображеннях

1. Gonzalez R. C., Woods R. E. *Digital Image Processing*, Fourth Edition, Global Edition. Pearson Education Limited, 2018, 120-303
2. Zhang A., Lipton Z. C. *Dive into Deep Learning*. Cambridge University Press, 2023, 239-273
3. Dey S. *Hands-On Image Processing with Python: Expert techniques for advanced image analysis and effective interpretation of image data*. Packt Publishing, 2018, 403-451
4. Bengio Y., Courville A., Goodfellow I. *Deep Learning*. MIT Press, 2016. 499-523
5. Mao X.-J., Shen C., Yang Y.-B. *Image Restoration Using Very Deep Convolutional Encoder-Decoder Networks with Symmetric Skip Connections*, arXiv:1603.09056, 2016
6. Yu J., Lin Z., Yang J., Shen X., Lu X., Huang T. *Generative Image Inpainting with Contextual Attention*, arXiv:1801.07892, 2018
7. Jiang J., Zuo Z., Wu G., Jiang K., Liu X. *A Survey on All-in-One Image Restoration: Taxonomy, Evaluation and Future Trends*, arXiv:2410.15067, 2024
8. Zhang K., Zuo W., Chen W., Meng D., Zhang L. *Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising*, arXiv:1608.03981, 2016
9. Pathak D., Krahenbuhl P., Donahue J., Darrell T., Efros A. *Context Encoders: Feature Learning by Inpainting*, arXiv:1604.07379, 2016
10. Nazeri K., Ng E., Joseph T., Qureshi F., Ebrahimi M. *EdgeConnect: Generative Image Inpainting with Adversarial Edge Learning*, arXiv:1901.00212, 2019
11. Bovik A. C. *Handbook of Image and Video Processing*. Academic Press, 2005, 117-161
12. Makhzani A., Shlens J., Jaitly N., Goodfellow I., Frey B. Adversarial Autoencoders, arXiv:1511.05644, 2016
13. Ronneberger O., Fischer P., Brox T. *U-Net: Convolutional Networks for Biomedical Image Segmentation*, arXiv:1505.04597, 2015
14. Keras 3 API documentation [електронний ресурс] <https://keras.io/api>
15. CBSD68 датасет [електронний ресурс] <https://github.com/claumichele/CBSD68-dataset>
16. CIFAR-10 датасет [електронний ресурс] <https://www.cs.toronto.edu/~kriz/cifar.html>



Дякую

за увагу!