

УДК 004.827

DOI <https://doi.org/10.32851/tnv-tech.2022.3.8>

ПРИНЦИПИ ОРГАНІЗАЦІЇ ПРОЦЕДУРИ МАШИННОГО АНАЛІЗУ НА ОСНОВІ ЗГОРТКОВОЇ НЕЙРОМЕРЕЖЕВОЇ АРХІТЕКТУРИ

Ткаченко М. С. – студент кафедри інформаційних систем та технологій факультету інформатики та обчислювальної техніки Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського»
ORCID ID: 0000-0002-5372-0883

Сокульський О. Є. – кандидат технічних наук, доцент кафедри інформатики та обчислювальної техніки факультету інформаційних систем та технологій Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського»
ORCID ID: 0000-0003-3853-992

Проведено огляд галузей застосування алгоритмів машинного аналізу, що базуються на моделі згорткової нейромережі. Визначено базову архітектуру згорткової нейромережі: організацію шарів нейромережі, принципи вибору функції активації та схему розрахунку функції втрат. Запропоновано комплексну методологію, що надає можливість провести організацію, налаштування та оптимізацію алгоритмів машинного аналізу, що базуються на моделі згорткової нейромережі відповідно цільових показників ефективності організації нейромережевого аналізу та навантаження на обчислювальний ресурс апаратно програмної платформи загального комплексу. Ефективність вирішення поставлених відповідно показників точності та адаптивності системи машинного аналізу, а також навантаження на обчислювальний ресурс і часу обробки даних залежить від особливостей організації нейромережевої архітектури та підходів, що використовуються у процесі навчання CNN. Автором було визначено принципи розробки цілісної та універсальної методології побудови нейромережевих алгоритмів на основі архітектури CNN, що характеризуються високою точністю машинного аналізу за умов мінімізації часу обробки даних при наявних обмеженнях на обчислювальний ресурс апаратно-програмної платформи. При цьому у рамках даного дослідження було проведено: визначення принципів побудови структури згорткової нейромережі глибокого навчання; формалізацію математичного апарату проведення процедури згортки; формалізацію математичного апарату проведення процедури пулінгу; модель організації процедури налаштування та оптимізації алгоритмів машинного аналізу, що базується на архітектурі згорткової нейромережі, на рівні кількісних показників.

Ключові слова: згорткові нейронні мережі, функція активації, функція втрат, ініціалізація параметрів, регуляризація ваги, ітераційні алгоритми оптимізації, цільова функція.

Tkachenko M. S., Sokulskiy O. Ye. Principles of machine analysis procedure organization based on convolutional neural network architecture

The areas of application of machine analysis algorithms based on the convolutional neural network model are reviewed. The basic architecture of the convolutional neural network is determined: the organization of neural network layers, the principles of activation function selection and the scheme of loss function calculation. The formalization of the learning process of the convolutional neural network based on preprocessing of data, parameters initialization, weights regularization and iterative optimizer algorithms selection is carried out. A complex methodology is proposed, which provides an opportunity to organize, configure and optimize machine analysis algorithms based on the model of convolutional neural network in accordance with the target performance efficiency of neural network analysis and the load on the computing resource of the general complex hardware and software platform.

The effectiveness of the solution of the assigned characteristics of the accuracy and adaptivity of the machine analysis system, as well as the load on the computing resource and the data processing time depends on the features of the neural network architecture organization and the approaches

used in the process of CNN training. The author has defined the principles of development of integral and universal methodology of neural network algorithms based on CNN architecture, which are characterized by high accuracy of machine analysis in conditions of data processing time minimization under the existing restrictions on the computing resource of hardware and software platform. At the same time in this research it was carried out: the definition of the principles of construction of the convolutional neural network structure of deep learning; formalization of the mathematical apparatus of the convolutional procedure; formalization of the mathematical apparatus of the pooling procedure; the model of the organization of the adjustment and optimization of machine analysis algorithms, based on the convolutional neural network architecture, on the quantitative indicators level.

Key words: convolutional neural networks, activation function, loss function, parameters initialization, weights regularization, iterative optimizer algorithms, target function.

Вступ. На сьогоднішній день галузі застосування алгоритмів машинного аналізу, що базуються на моделі згорткової нейромережі (Convolutional Neural Network, CNN) включають у себе попередню і пост-обробку графічних даних, виділення і класифікацію візуальних об'єктів, побудову тривимірної сцени, сегментацію матриці зображення, тощо. Це вказує на можливість їх застосування при роботі з широким колом задач, як то машинний аналіз медичних фотоданих [1; 2], обробка даних супутникової і аеро-зйомки [3; 4], організація систем аутентифікації за біометричними показниками і запобігання правопорушень зі застосуванням даних систем відеореєстрації [5; 6], розпізнавання текстових блоків, представлених у растровому вигляді [7; 8], тощо. Ефективність вирішення поставлених відповідно показників точності та адаптивності системи машинного аналізу, а також навантаження на обчислювальний ресурс і часу обробки даних залежить від особливостей організації нейромережевої архітектури та підходів, що використовуються у процесі навчання CNN.

Аналіз сучасних досліджень і публікацій присвячених проблемам впровадження алгоритмів машинного аналізу масивів графічних даних на основі CNN вказав на основні підходи, що використовуються при класифікації зображень (моделі LeNet-5, AlexNet, ZFNet, VGGNet, GoogLeNet, ResNet і DenseNet) нейромережевими алгоритмами [9-15], виділення візуальних об'єктів через застосування нейромережевої архітектури R-CNN, Fast R-CNN, Faster R CNN, SPP-Net, Mask R-CNN і YOLO [16-21], а також методів сегментації матриці зображення на основі повнозв'язної CNN (Fully Convolutional Network, FCN) та програмними додатками DeepLab, Deconvnet, SegNet, DeepMask, SharpMask, U Net, PANet та TensorMask [22-31]. Проведений аналіз вказав на **актуальність** вирішення завдання побудови загальних підходів, що базуються на визначенні кількісних цільових показників, по організації нейромережевих алгоритмів машинного аналізу великих масивів даних у режимі реального часу. Відсутність у представлених дослідженнях універсальної методології, що надає можливість сформувати принципи розробки зазначених алгоритмів, розглядається, відповідно, як **невирішена частина загального дослідження**.

Таким чином, **метою дослідження** стала розробка цілісної методології побудови нейромережевих алгоритмів на основі архітектури CNN, що характеризуються високою точністю машинного аналізу та якістю обробки вхідних даних за умов мінімізації навантаження на обчислювальний ресурс та часу обробки даних, які можуть бути ефективно використані при роботі з широким колом задач.

1. Особливості організації архітектури згорткової нейромережі

Аналіз базової схеми CNN вказує, що переваги даної архітектури при роботі з графічними даними (узагальнення різнорідних фото-даних і виділення ознак глибокого рівня, зокрема розташування візуального об'єкту та оцінка естетичності

складових зображення), пов'язані з організацією структури CNN, як то наявністю повнозв'язних (Fully Connected, FC) шарів і моделлю прямого розповсюдження (Deep Feed-Forward Architecture, DF-FA), що може бути ефективно організована як нейромережа глибокого навчання [32; 33]. В загальному вигляді архітектура CNN глибокого навчання складається з сандвіч-структури згорткових та пулінгових шарів, що організовані у відповідні набори, де кожен наступний набір виділяє ознаки з більшим рівнем абстракції. Як показано на рис. 1, якщо сандвіч-структура складається з N -наборів, то загальна кількість шарів, що включатиме вхідний і вихідний, а також FC-шар, розраховується як $(2N + 3)$.

Можна вказати, що переваги нейромережових алгоритмів на основі архітектури CNN при відновленні, обробці і аналізі графічних даних можуть бути формалізовані наступним чином: (i) функція розподілу ваги, яка зменшує кількість параметрів і надає можливість уникнути типової проблеми перенавчання нейромережі; (ii) навчання шарів, що відповідають за виділення і класифікацію ознак у рамках однієї процедури, що збільшує цілісність та точність проведення процедури машинного аналізу; (iii) спрощена схема модифікації та масштабування CNN при зміні та розширенні набору поставлених задач.

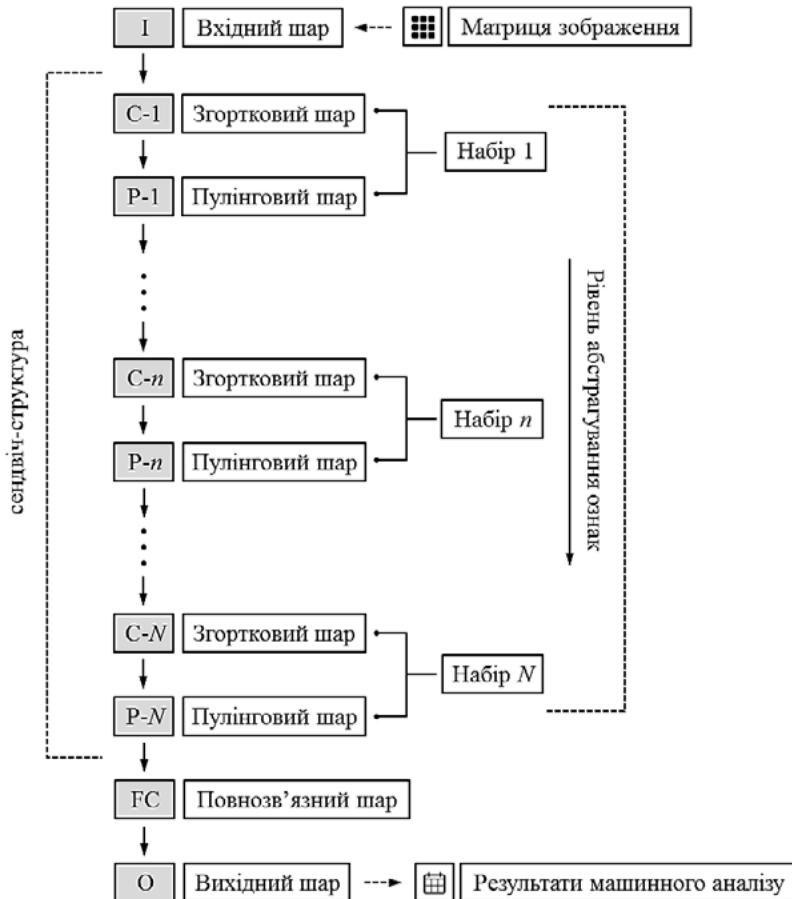


Рис. 1. Базова структура згорткової нейромережі глибокого навчання
Джерело: власна розробка автора

На рівні кожного загорткового шару, що характеризується розміром ядра згортки (Convolutional Kernel, СК), що виконує роль фільтра, здійснюється процедура згортки зображення відповідно заданої метрики для побудови карти ознак (Feature Map, FM). При цьому СК представляє собою матрицю значень, що є вагами ядра, налаштування яких відповідає процесу навчання. Під час обробки графічних даних матриця зображення розбивається на колірні канали і надалі обробляється по багатоканальній схемі, що кратно збільшує швидкість машинного аналізу. Для кожного каналу на основі СК проводиться сканування матриці зображення через зміщення СК на відповідний крок згортки (Convolutional Stride, CS). Слід зазначити, що розмір CS має бути меншим СК для забезпечення часткового перекриття у процесі сканування. CS є аргументом цільових функцій вибір якого відповідає задачі дослідження: при збільшенні CS зменшується навантаження на обчислювальний ресурс і час обробки даних, але водночас зменшується розмірність FM, що, очевидним чином, негативно впливає на ефективність машинного аналізу. Недоліком базового підходу, представленого вище, є те, що периферійні елементи матриці зображення (пікселі) приймають участь у меншій кількості згорток. Це може бути вирішено через застосування операції доповнення зображення (Convolution Padding, CP), що застосовується безпосередньо перед проведенням процедури згортки. Згортки, у яких застосовується CP з метою збереження розмірності матриці зображення класифікуються як «однакові» (Same Convolution, SC), а згортки з нульовим доповненням – «правильними» (Valid Convolution, VC).

Відповідно проведеній формалізації виконання процедури згортки, розмірність карти ознак $X_G \times Y_G$, що отримується на виході загорткового шару при розмірності матриці вхідного зображення $X \times Y$ визначається наступними чином:

$$\begin{cases} X_C = \left\lfloor 1 + \frac{X - S_{CK} + S_{CP}}{S_{CS}} \right\rfloor \\ Y_C = \left\lfloor 1 + \frac{Y - S_{CK} + S_{CP}}{S_{CS}} \right\rfloor \end{cases}, \quad (1)$$

де S_{CK} – розмірність матриці СК, S_{CP} – доповнення згортки, а S_{CS} – розмір CS. Алгоритм розрахунку може бути розширено для прямокутно CK, через перехід для розрахунку X_C від S_{CK} до $X S_{CK}$, а для Y_C від S_{CK} до $Y S_{CK}$. Загальною перевагою застосування згорткових шарів у неймережевій архітектурі є розріджена зв'язність (тобто відсутність повного набору зв'язків між всіма нейронами сусідніх шарів) та розподіл вагових коефіцієнтів, що у даному випадку не є унікальними для двох окремих нейронів, а відповідає виключно їх зв'язку з елементами вхідних даних, як то пікселями матриці вхідного зображення. Це значно спрощує виконання процедур навчання та машинного аналізу відповідно показників навантаження на обчислювальний ресурс та часу обробки запиту.

Також, як це показано на рис. 1 необхідним елементом архітектури CNN є пулінгові шари, що використовуються для стиснення карт ознак, як додатковий засіб зменшення навантаження на обчислювальний ресурс. Ефективність операції пулінгу визначається через співвіднесення рівня стиснення та мінімізації втрат значимих ознак та точності класифікації. Подібно до операції згортки, операція пулінгу характеризується розміром ядра пулінгу (Pooling Kernel, PK) та кроком сканування (Pooling Stride, PS). Поза відповідних значень S_{PK} і S_{PS} , у якості аргументу цільової функції розглядається і сама функція, на основі якої здійснюється операція пулінгу, як то $F_{P\uparrow}$ – пулінг на основі максимального значення (Max Pooling, MP), $F_{P\downarrow}$ – пулінг на основі мінімального значення (Max Pooling, MP),

F_{AP} – пулінг на основі середнього значення (Average Pooling, AP) та інші підходи, відповідно поставленої задачі, зокрема гібридні схеми [32; 33]. У свою чергу, передостанній шар нейромережевої архітектури – «FC» використовується у якості класифікатора, що об'єднує карти ознак з найвищим рівнем абстрагування. Як це показано на рис. 1 відповідний шар є повнозв'язним по відношенню до останнього пулінгового шару «P-N» і вихідного шару «O».

2. Вибір функції активації та функції втрат згорткової нейромережі

На цільові показники нейромережевого аналізу також впливає вибір функції активації (Activation Functions, AF), що на основі суми вхідних даних нейронів з урахуванням зміщення (за наявності нейронів зміщення) визначає умову спрацювання окремого нейрона. У CNN глибинного навчання для представлення нелінійного відображення між масивом даних на вході та на виході використовується нелінійна AF. Також слід зазначити для організації навчання CNN за методом зворотного поширення помилки використовується диференційована AF. Такими чином, актуальний набір AF, що розглядається у рамках дослідження, включає у себе такі як:

- сигмоїда ($A_{Sig}(x)$);
- функція Tanh ($A_{Tanh}(x)$);
- функція ReLu ($A_{ReLu}(x)$), а також побудовані на її основі функції «Leaky ReLU» ($A_{LR}(x)$) і «Noisy ReLU» ($A_{NR}(x)$).

Наведемо математичне представлення зазначених функцій у рамках математичного апарату, що використовується у даному дослідженні:

$$\left[\begin{array}{l} A_{Sig}(x) = (1 + e^{-x})^{-1} \\ A_{Tanh}(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \\ A_{ReLu}(x) = \max_x(0; x) \\ A_{LR}(x) = \begin{cases} x & \text{при } x > 0 \\ \mu x & \text{при } x \leq 0 \end{cases} \\ A_{NR}(x) = \max_x(x + b), \text{ де } b \sim F(0; \sigma(x)) \end{array} \right. \quad (2)$$

У свою чергу, цільовий показник точності машинного аналізу визначається на основі функції втрат (Loss Function, LF), а відповідно пошук її глобального мінімуму надає можливість на кількісному рівні вирішити задачу оптимізації нейромережевого алгоритму. На загальному рівні функція втрат базується на співвіднесенні істинних (умовно істинних) параметрів як набору P_i з результатами роботи CNN як набору P'_i , де $i \in [1; I]$, причому сама реалізація даної процедури залежить від класу задач, яка виконується на рівні застосування відповідного нейромережевого алгоритму [32; 33].

Розглянемо наступні форми представлення функції втрат, що можуть бути використані в рамках представленої дослідження:

- $L_{SM}(P, P')$ – функція «Soft-Max»;
- $L_E(P, P')$ – функція втрат на основі евклідової метрики (Euclidean Loss Function, ELF);
- $L_H(P, P')$ – кусково-лінійна функція втрат (Hinge Loss Function, HLF).

Аналогічно, математичне представлення зазначених функцій у рамках математичного апарату, що використовується у даному дослідженні може бути проведено наступним чином:

$$\left[\begin{array}{l} L_{SM}(P, P') = - \sum_{i=1}^I (P_i \cdot \log(P'_i)) \\ L_E(P, P') = \frac{\sum_{i=1}^I (P_i - P'_i)^2}{2I} \\ L_H(P, P') = \sum_{i=1}^I (\max(0, \mu - P'_i \cdot (2P_i - 1))) \end{array} \right. \quad (3)$$

Вибір функції втрат та експериментальне визначення часу обробки запиту при фіксованій архітектурі апаратно-програмного комплексу формують повний набір цільових функцій. Через варіювання аргументів цільових функцій з метою пошуку глобальних мінімумів проводиться процедура оптимізація архітектури CNN.

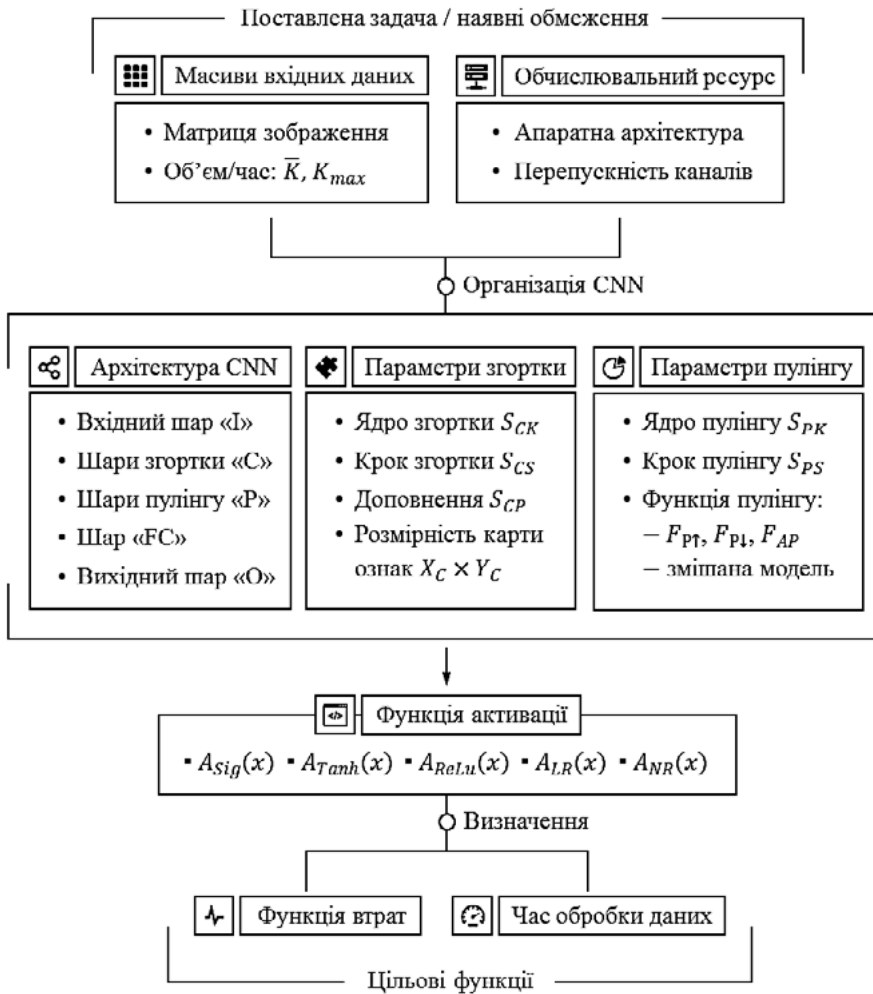


Рис. 2. Схема налаштування та оптимізація алгоритмів машинного аналізу, що базується на архітектурі згорткової нейромережі

Джерело: власна розробка автора

3. Розробка, налаштування та оптимізація алгоритмів машинного аналізу, що базуються на моделі згорткової нейромережі

Алгоритм налаштування та оптимізації процедури машинного аналізу, що базуються на архітектурі CNN у загальному вигляді складається з наступного набору етапів (рис. 2):

1. Визначення типової архітектури апаратно-програмної платформи, що дозволяє оцінити обчислювальний ресурс системи машинного аналізу на основі CNN;
2. Визначення типових параметрів вхідних даних (розмірність матриці зображення $X \times Y$ та кількість зображень, що підлягають аналізу на одиницю часу \bar{K}, K_{max});
3. Архітектура CNN глибинного навчання, що визначається через шари «I», «С- n », «Р- n », «FC» і «O»;
4. Параметри згортки: розмірність матриці ядра згортки, розмір доповнення згортки, розмір кроку сканування;
5. Параметри пулінгу: розмірність матриці ядра пулінгу, розмір кроку сканування, а також функція, на основі якої здійснюється операція пулінгу;
6. Вибір функції активації і параметрів функції активації;
7. Розрахунок функції втрат машинного аналізу та визначення часу обробки вхідного запиту;
8. Мінімізація цільових функцій втрат та часу обробки через корегування параметрів нейромережевого алгоритму.

Розширення даного алгоритму можливо через включення у параметри цільових функцій особливості навчання нейромережевих алгоритмів та попередню обробку вхідних даних, що у свою чергу призводить до необхідності включення у цільові функції час навчання та час попередньої обробки.

Висновки. У результаті проведеної роботи було визначено принципи розробки цілісної та універсальної методології побудови нейромережевих алгоритмів на основі архітектури CNN, що характеризуються високою точністю машинного аналізу за умов мінімізації часу обробки даних при наявних обмеженнях на обчислювальний ресурс апаратно-програмної платформи.

При цьому у рамках даного дослідження було проведено:

- визначення принципів побудови структури згорткової нейромережі глибинного навчання;
- формалізацію математичного апарату проведення процедури згортки;
- формалізацію математичного апарату проведення процедури пулінгу;
- модель організації процедури налаштування та оптимізації алгоритмів машинного аналізу, що базуються на архітектурі згорткової нейромережі, на рівні кількісних показників.

BIBLIOGRAPHY:

1. Zhao, Y., Ge, F., & Liu, T. (2018). Automatic recognition of holistic functional brain networks using iteratively optimized convolutional neural networks (IO-CNN) with weak label Initialization. *Medical Image Analysis*, 47, 111–126. <https://doi.org/10.1016/j.media.2018.04.002>.
2. Li, B., Keikhosravi, A., Loeffler, A. G., & Eliceiri, K. W. (2021). Single image super-resolution for whole slide image using convolutional neural networks and self-supervised color normalization. *Medical Image Analysis*, 68, 101938. <https://doi.org/10.1016/j.media.2020.101938>.
3. Maggiori, E., Tarabalka, Y., Charpiat, G., & Alliez, P. (2017). Convolutional neural networks for large-scale remote-sensing image classification. *IEEE Transactions on*

Geoscience and Remote Sensing, 55(2), 645–657. <https://doi.org/10.1109/tgrs.2016.2612821>.

4. Ji, C., & Tang, H. (2020). Number of building stories estimation from monocular satellite image using a modified mask R-CNN. *Remote Sensing*, 12 (22), 3833. <https://doi.org/10.3390/rs12223833>.

5. Rasti, P., Uiboupin, T., Escalera, S., & Anbarjafari, G. (2016). Convolutional Neural Network Super resolution for face recognition in surveillance monitoring. *Articulated Motion and Deformable Objects*, 175–184. https://doi.org/10.1007/978-3-319-41778-3_18.

6. Kumar, S., & Singh, S. K. (2020). Occluded thermal face recognition using bag of CNN. *IEEE Signal Processing Letters*, 27, 975–979. <https://doi.org/10.1109/lsp.2020.2996429>.

7. Opitz, M., Diem, M., Fiel, S., Kleber, F., & Sablatnig, R. (2014). End-to-end text recognition using local ternary patterns, mserr and deep convolutional nets. *2014 11th IAPR International Workshop on Document Analysis Systems*. <https://doi.org/10.1109/das.2014.29>.

8. Wang, Z.-R., Du, J., & Wang, J.-M. (2020). Writer-aware CNN for parsimonious HMM-based offline handwritten Chinese text recognition. *Pattern Recognition*, 100, 107102. <https://doi.org/10.1016/j.patcog.2019.107102>.

9. Verdhan, V. (2021). Image classification using LeNet. *Computer Vision Using Deep Learning*, 67–101. https://doi.org/10.1007/978-1-4842-6616-8_3.

10. Zhang, X., Pan, W., & Xiao, P. (2018). In-vivo skin capacitive image classification using AlexNet Convolution Neural Network. *2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)*. <https://doi.org/10.1109/icivc.2018.8492860>.

11. Kaddoun, S. S., Aberni, Y., Boubchir, L., Raddadi, M., & Daachi, B. (2021). Convolutional Neural Algorithm for palm vein recognition using ZFNet architecture. *2021 4th International Conference on Bio-Engineering for Smart Technologies (BioSMART)*. <https://doi.org/10.1109/biosmart54244.2021.9677799>.

12. Chaudhari, S., Sardar, V., Rahul, D. S., Chandan, M., Shivakale, M. S., & Harini, K. R. (2021). Performance analysis of CNN, Alexnet and vggnet models for drought prediction using satellite images. *2021 Asian Conference on Innovation in Technology (ASIANCON)*. <https://doi.org/10.1109/asiancon51346.2021.9545068>.

13. Teymounezhad, K., Azgomi, H., & Asghari, A. (2022). Detection of counterfeit banknotes by security components based on image processing and GoogLeNet Deep Learning Network. *Signal, Image and Video Processing*. <https://doi.org/10.1007/s11760-021-02104-z>.

14. M., N. K. (2020). Breast cancer classification of image using modified ResNet. *Journal of Advanced Research in Dynamical and Control Systems*, 12(3), 134–140. <https://doi.org/10.5373/jardcs/v12i3/20201175>.

15. Li, G., Zhang, C., Lei, R., Zhang, X., Ye, Z., & Li, X. (2019). Hyperspectral remote sensing image classification using three-dimensional-squeeze-and-excitation-densenet (3D-Se-DenseNet). *Remote Sensing Letters*, 11(2), 195–203. <https://doi.org/10.1080/2150704x.2019.1697001>

16. Wang, X., Ma, H., & Chen, X. (2016). Salient object detection via Fast R-CNN and low-level cues. *2016 IEEE International Conference on Image Processing (ICIP)*.

17. Adam, B., Zaman, F., Yassin, I., Abidin, H., & Rizman, Z. (2018). Performance evaluation of faster R-CNN on GPU for object detection. *Journal of Fundamental and Applied Sciences*, 9 (3S), 909.

18. Kızılluluk, S., & Sert, E. (2022). Hurricane-faster R-CNN-JS: Hurricane Detection with faster R-CNN using artificial Jellyfish Search (JS) optimizer. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-022-13156-9>.

19. Wei, X., Xie, C., Wu, J., & Shen, C. (2018). Mask-CNN: Localizing parts and selecting descriptors for fine-grained bird species categorization. *Pattern Recognition*, 76, 704–714.

20. Yan, W., Liu, T., & Fu, Y. (2021). Yolo-tight: An efficient dynamic compression method for Yolo Object Detection Networks. *2021 13th International Conference on Machine Learning and Computing*. <https://doi.org/10.1145/3457682.3457740>.
 21. Du, J. (2018). Understanding of Object Detection Based on CNN Family and YOLO. *Journal of Physics: Conference Series*, 1004, 012029.
 22. Qin, P. (2019). Fully convolutional-based dense network for lung nodule image retrieval algorithm. *International Journal of Performability Engineering*. <https://doi.org/10.23940/ijpe.19.01.p33.326336>.
 23. Cai, Y., & Li, Q. (2021). DeepLab network for Meteorological Trough Line Recognition. *2021 4th International Conference on Sensors, Signal and Image Processing*. <https://doi.org/10.1145/3502814.3502820>.
 24. Mukherjee, A., Chakraborty, S., & Saha, S. K. (2019). Detection of loop closure in slam: A DeconvNet based approach. *Applied Soft Computing*, 80, 650–656. <https://doi.org/10.1016/j.asoc.2019.04.041>.
 25. Saood, A., & Hatem, I. (2020). Covid-19 lung CT image segmentation using deep learning methods: UNET vs. segnet. <https://doi.org/10.21203/rs.3.rs-56882/v2>.
 26. Wang, P., Xiong, L., & Dan, B. (2021). Surface vortex image segmentation in KR desulfurization based on improved SegNet model. *2021 China Automation Congress (CAC)*. <https://doi.org/10.1109/cac53003.2021.9728231>.
 27. Son, S.-B., Jung, J.-U., Oh, H.-S., & Jung, Y.-chul. (2020). DeepMask: Face masking system using deep neural networks on real-time streaming. *Journal of Institute of Control, Robotics and Systems*, 26 (6), 423–428. <https://doi.org/10.5302/j.icros.2020.20.0029>.
 28. Trullo, R., Petitjean, C., Ruan, S., Dubray, B., Nie, D., & Shen, D. (2017). Segmentation of organs at risk in thoracic CT images using a SharpMask architecture and conditional random fields. *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*. <https://doi.org/10.1109/isbi.2017.7950685>.
 29. Hu, X., & Yang, H. (2020). Dru-Net: A novel U-Net for biomedical image segmentation. *IET Image Processing*, 14(1), 192–200. <https://doi.org/10.1049/iet-ipr.2019.0025>.
 30. Wang, K., Liew, J. H., Zou, Y., Zhou, D., & Feng, J. (2019). Panet: Few-shot image semantic segmentation with prototype alignment. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*. <https://doi.org/10.1109/iccv.2019.00929>.
 31. Chen, X., Girshick, R., He, K., & Dollár, P. (2019). TensorMask: A foundation for dense object segmentation. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*. <https://doi.org/10.1109/iccv.2019.00215>.
 32. Ghosh A., et al., (2020) *Fundamental Concepts of Convolutional Neural Network*. En Balas V., Kumar R., Srivastava R. (eds) Recent Trends and Advances in Artificial Intelligence and Internet of Things. Intelligent Systems Reference Library. Springer. https://doi.org/10.1007/978-3-030-32644-9_36.
 33. Qin, Z., et al., (2018). How convolutional neural networks see the world. A survey of convolutional neural network visualization methods. *Mathematical Foundations of Computing*, 1(2): 149-180. <https://doi.org/10.3934/mfc.2018008>.
-