

## ОСОБЛИВОСТІ ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ У ЗАДАЧАХ ЗМЕНШЕННЯ ШУМУ ЦИФРОВИХ ЗОБРАЖЕНЬ

### Олексій Переверзєв

аспірант кафедри акустичних та мультимедійних електронних систем

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського»,  
просп. Берестейський, 37, Київ, Україна, 03056

ORCID: 0000-0002-8208-3449

### Кирило Трапезон

кандидат технічних наук, доцент, доцент кафедри акустичних та мультимедійних електронних систем

Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського»,  
просп. Берестейський, 37, Київ, Україна, 03056, kirill.trapezon@gmail.com

ORCID: 0000-0001-5873-9519

Нейронні мережі останнім часом набувають усе більшої популярності в різних сферах мультимедійних систем технічного зору завдяки тому, що їх можна використовувати в режимі високопродуктивних паралельних обчислень, тобто вони визначаються високою обчислювальною ефективністю. Одним із їх практичних застосувань визначають алгоритми та процедури зменшення шуму в кольорових зображеннях. Особливо ефективним виявилося їх використання в медичній та військовій сферах. У першому випадку нейронна мережа дає змогу зберегти потрібну якість зображення, наприклад під час отримання рентгенівських знімків у системах комп'ютерної томографії. У другому випадку такі мережі дуже допомагають у системах супутникової зйомки, особливо коли необхідно зберегти деталі на фотографіях під час проведення розвідки місцевості з висоти або на основі радіолокаційних засобів.

У статті наведено наскрізну глибоку нейронну мережу згорткового типу для зменшення адаптивного білого шуму в зображеннях на основі стратегії залишкового навчання цієї мережі. Отримана модель мережі визначається певним рівнем стійкості, що є наслідком проведеного аналізу та наявністю прихованих адаптивних згорткових шарів в її архітектурі. Отримано, що на етапі навчання розроблена мережа показує високі показники, що дає змогу її адаптувати у майбутньому для роботи зі складними зображеннями, які перенасичені деталями та визначаються високою роздільною здатністю. Проведений режим експерименту з тренування нейронної мережі показав, що мережа ефективно видаляє адитивний білий шум. Наприклад, для рівня дисперсії шуму ефективність становила приблизно 8 дБ для метрики пікового відношення «сигнал – шум». Наведені результати дослідження можуть бути використані у подальшому для інших застосувань у системах технічного зору, зокрема під час вирішення задач аналізу зображень в електронних системах відеоспостереження.

**Ключові слова:** мережа, зображення, алгоритм, шум, шар, згортка, аналіз, модель.

**Вступ, актуальність роботи.** Проблема зменшення шуму під час оброблення цифрових повнокольорових зображень для створення якісного мультимедійного контенту є однією з основних сьогодні, особливо коли йдеться про ефективність функціонування мультимедійних систем технічного зору [1]. Насправді, про шум, його присутність та подальший аналіз можна говорити на всіх етапах роботи із зображеннями (зйомка, оцифрування, передавання, стиснення). І на всіх цих етапах через особливості роботи приладів фіксації зображення, переведення його у цифрову форму застосування алгоритмів оброблення шум має ознаки накопичення в зображенні. Ба більше, наявність шуму може призводити до зниження чіткості зображення і неможливості точного визначення деталей та границь на площині цього зображення [2].

У деяких умовах накопичення шуму може бути критичним з огляду на оцінку елементів самого зображення. Наприклад, у медичній інженерії наявність значного шуму під час отримання низько контрастних зображень за допомогою комп'ютерного томографа може бути причиною неточного діагнозу пацієнта під час лікування [3; 4]. При цьому слід урахувати, що і саме рентгенівське випромінювання додає до зображення артефакти, які викликані так званім ефектом «променевого зміцнення».

Шум та його наявність у системах супутникової зйомки можуть бути чинниками втрати деталей під час проведення розвідки місцевості. У цьому плані цікавим виглядає дослідження, яке представлено в роботі [5]. Так, автори наголошують, що супутникове радіолокаційне зображення

із синтезованою апертурою є складним із погляду аналізу через те, що в їхній структурі є спекл-шум. І цей вид шуму для якісної оцінки роботи радіолокаційної станції необхідно обов'язково відфільтрувати перед обробкою зображення. Цим самим можна досягти точності оброблення, однозначності виділення ознак зображення.

У статті [6] аналіз зображення, процедури його відновлення розглядаються для прикладних застосувань у сфері дерматології. Зокрема, у роботі порушується проблема підвищення різкості розмитих зображень на основі аналізу ядра розмитості. Додатково наголошується, що розмиття елементів зображення як різновид шуму є основною причиною погіршення якості зображення у цій прикладній сфері. Тобто на основі оцінки ядра розмитості зображення автори статті намагаються отримати покращення за характеристиками розрідженості зображення. У доповнення до цього в роботі [7] міститься теза, що видалення шуму в зображеннях є головним завданням під час їх оброблення, оскільки нехтування цим фактором призводить до втрати корисної інформації. Корисним у цьому плані виявляється, що для збереження країв та кутів об'єктів на площині зображення автори пропонують використовувати підхід анізотропної дифузії.

У дослідженні [8] розглядається так званий «стега-шум» у зображенні та підходи до його зменшення. Насамперед, стеганографічний аналіз є цікавою сферою, оскільки розкриває питання створення секретних повідомлень у різних видах аудіовізуального контенту, у тому числі й у зображеннях.

Таким чином, наведений огляд літературних джерел свідчить про актуальність поставлених завдань, пов'язаних зі зменшенням шуму в зображеннях. У цій роботі ми зосередимо основну увагу саме на розгляді адитивного білого шуму через те, що він найчастіше зустрічається сьогодні під час оброблення зображень.

У теорії оброблення сигналів, до яких можна віднести як статичне, так і рухоме зображення, найчастіше виділяють два види шуму – адитивний та мультиплікативний.

Якщо прийняти, що  $c(x)$  – чисте зображення без шуму, то зображення з шумом можна записати як

$$N(x) = c(x) + n(x),$$

де  $N(x)$  – версія з шумом зображення  $c(x)$ ;  $n(x)$  – шум, який був доданий до  $N(x)$ . У загальному випадку вплив шуму  $n(x)$  на зображення можна виразити через оператор-функцію

$$N(x) = \Phi[c, n],$$

і коли оператор-функція  $\Phi$  вироджується у математичну операцію підсумовування, то говорять, що на зображення впливає адитивний шум.

**Постановка завдання, мета, завдання дослідження.** Сьогодні відомі різні підходи та способи, які дають змогу зменшити шум у зображенні. Серед них можна відзначити метод градієнтного спуску, стохастичний метод, метод аналізу незалежних компонентів зображення і нелокальні методи, до числа котрих відноситься метод еталонного алгоритму блокового зіставлення та 3D-фільтрації. Разом із тим переважно всі вони мають обмеження, які пов'язані з тим, що вони потребують залучення значних обчислювальних потужностей у ситуації, коли характеристики шуму можуть змінюватися в режимі реального часу. Окрім цього, результатом роботи цих методів може бути видалення деталей зображення, додавання розмитості контурів зображення. До того ж у деяких ситуаціях виникають питання щодо їх точності роботи під час видалення оптичних артефактів зображення. Моделі, які можуть бути створені на основі нелокальних методів, добре відновлюють сфери зображення з повторювальними частинами, але разом із тим вони залишають після себе «залишковий шум» і спричиняють появу додаткового розмиття зображення. Ще більше ситуація ускладнюється, коли необхідно провести сліпе зменшення шуму в зображенні.

Тобто під час оброблення зображень із різною роздільною здатністю необхідно знайти компроміс між швидким і точним зменшенням шуму і збереженням найменших деталей зображення. Це завдання успішно вирішує використання глибоких нейронних мереж згорткового типу з прямим зв'язком. Іншими словами, за результатами роботи нейронної мережі певної архітектури необхідно отримати чисте зображення без шуму на основі операцій у схованих згорткових шарах цієї мережі.

Метою роботи є розроблення архітектури наскрізної глибокої нейронної мережі згорткового типу для зменшення адитивного білого шуму в повнокольорових зображеннях зі стратегією залишкового навчання. Окрім цього, необхідно забезпечити стійкість спроектованої нейронної мережі та гнучкість. Для досягнення поставленої мети необхідно виконати такі завдання:

– розробити архітектуру нейронної мережі згорткового типу для зменшення адитивного шуму в кольорових зображеннях;

– визначити основні якісні характеристики метрики, які б дали змогу оцінити ефективність запропонованої архітектури нейронної мережі;

– провести практичний експеримент із визначення ефективності роботи створеної нейронної мережі щодо зменшення адитивного білого шуму у вибраному зображенні з артефактами.

**Матеріал, результати досліджень.** Нейронна мережа згорткового типу визначається певною структурою, і основною частиною в ній є шар згортки, який можна розглядати як певний згортувальний цифровий фільтр розміром  $k \times k$ . У цілому дана мережа являє собою послідовність цих шарів, і ці шари визначаються нелінійними функціями активації.

Для оцінки якості роботи нейронної мережі щодо зменшення шуму в зображенні розраховують певні параметри.

Метрика пікового відношення сигнал-шум визначається на основі такого співвідношення [1]:

$$PSNR(X, Y) = 10 \lg \left( \frac{(L)^2}{\frac{1}{NM} \sum_{i,j} (X_{i,j} - Y_{i,j})^2} \right), \quad (1)$$

де

$X$  – оригінальне зображення;

$Y$  – отримане зображення зі зменшеним шумом як результат роботи нейронної мережі;

$L = 255$  – динамічний діапазон зміни яскравостей для області розміром  $N \times M$  пікселів зображення.

Як правило, ця метрика використовується для двох пар зображень: оригінального та шумового ( $PSNR_1$ ); оригінального і відновленого зображення без шуму ( $PSNR_2$ ). Чим більше різниця в дБ між значеннями  $PSNR_2$  і  $PSNR_1$ , тим якісніше працює нейронна мережа щодо завдання усунення шуму.

Індекс структурної подібності зображень можна визначити за формулою:

$$SSIM = \frac{(2m_x m_y + C_1)(2\sigma_{xy} + C_2)}{(m_x^2 + m_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}, \quad (2)$$

де

$m_x, m_y$  – математичне очікування зображень  $X$  та  $Y$ ;

$\sigma_x, \sigma_y$  – дисперсія зображень  $X$  та  $Y$ ;

$\sigma_{xy}$  – взаємна дисперсія зображень  $X$  та  $Y$ ;

$C_1 = (k_1 L)^2$ ;  $C_2 = (k_2 L)^2$ ;  $k_1 = 0,01$ ;  $k_2 = 0,03$ .

Для спрощення прийемо, що адитивний білий шум має нульове математичне очікування, а дисперсія шуму (рівень шуму) визначається з ряду 15, 25, 50. Визначимо, що нейронна мережа складається з трьох частин і має 40 згорткових шарів. На рис. 1 наведено структурну схему запропонованої нейронної мережі з прямим каскадним зв'язком, особливістю якої є наявність залишкового модуля з двох згорткових шарів (на рис. 1 не показано).

Частина А структурної схеми нейронної мережі відповідає за відокремлення ознак зображення з шумом. До цієї частини входить згортковий шар із 64 фільтрів, кожен з яких має розмір  $3 \times 3 \times C$ , де  $C$  – кількість каналів зображення. Для кольорового зображення  $RGB$   $C = 3$  [9]. Тобто маємо 64 області захоплення. Розмір області аналізу визначимо як  $N \times M = 40 \times 40$  елементів зображення.

Частина Б структурної схеми містить 16 залишкових блоків, кожен з яких складається з двох згорткових шарів, і кожен шар, своєю чергою, має функцію активації випрямлених лінійних одиниць. Тобто для врахування нелінійності під час відокремлення ознак зображення у структурі роботи нейронної мережі додається як окремий шар – точкова функція активації випрямлених лінійних одиниць. Пакетна нормалізація (нормалізація ознак у кожному шарі згортки) у запропонованій структурі не проводиться через те, що вона може видалити оригінальні особливості зображення (текстурні деталі) і призводить до їх розмиття.

Частина В структурної схеми характеризується одним згортковим шаром, який необхідний для обробки вихідного зображення (фільтр




Рис. 1. Структурна схема нейронної мережі

$3 \times 3 \times 64$ ). Для кольорового зображення кількість таких фільтрів дорівнює 3. Цей шар використовується для відновлення вихідного зображення.

На основі вейвлет-перетворення вихідного зображення всі шари схеми розподілено між декількома незалежними підмережами, кожна з яких визначається чотирма згортковими шарами, які розташовані паралельно в мережі основи. Кожна підмережа має свій вхід та вихід і керується власною функцією втрат для захоплення особливостей зображення [10]. У результаті роботи нейронної мережі в першому шарі створюється карта шуму і для білого адитивного шуму, що є предметом розгляду в статті, ця карта має бути однорідною.

Передбачається, що нейронна мережа, структурна схема якої показана на рис. 1, до тренування проходить режим навчання за архітектурою DenseNet на основі відповідного фреймворку Tensor Flow [10]. Вибір такої архітектури для навчання зумовлений тим, що при цьому всі попередні згорткові шари мережі з'єднуються з наступними без вибіркового відкидання, як це зроблено в архітектурі ResNet.

**Результати досліджень.** Після завершення конструювання нейронної мережі з підмережами (на рис. 1 не показано) необхідно провести етап навчання для подальшої оптимізації параметрів у мережі. Як базовий метод навчання для мережі виберемо метод Адама (метод стохастичної оптимізації) [11]. Для проведення навчання створеної мережі створимо програму на основі інструментальних засобів у середовищі Matlab. Кількість циклів навчання визначимо на рівні 600. Окрім цього, приймемо, що швидкість навчання становить 0,001. Для навчання виділимо в зображенні блок розміром  $25 \times 25$  пікселів. Для оцінки якості навчання визначимо функцію втрат (крива сходження нейронної мережі). Значення функції втрат будемо визначати на основі такого співвідношення [12]:

$$Loss = \frac{1}{n} \sum_{i=1}^n \left( \frac{1}{w \cdot h} \sum_{j=1}^w \sum_{k=1}^h \|f_i(j, k) - X_i(j, k)\|^2 \right), \quad (3)$$

де

$f$  – зображення після очищення від шуму;

$X$  – оригінальне зображення без шуму;

$n$  – число семплів у кожному тренувальному пакеті;

$h$  – висота семплу;

$w$  – ширина семплу.

За результатами проведених розрахунків у табл. 1 та на рис. 2 представлено дві графічні

залежності пронормованої функції втрат від кількості циклів навчання у разі використання розробленої нейронної мережі. З аналізу отриманих результатів можна зробити висновок, що розроблена нейронна мережа (рис. 1) на етапі навчання демонструє високі показники за критерієм зроблених помилок за видалення шуму із зображення. Зокрема, за збільшення циклів навчання для першого тестового зображення (рис. 2) можна побачити, що функція втрат за співвідношенням (3) стрімко зменшується з 0,45 до 0,0011. Під час запуску на навчання другого тестового зображення значення функції втрат вже є значно меншою. Ця особливість може свідчити про те, що навчання мережі відбувається успішно і точність проведення процедур збільшується.

Наприклад, на рівні проведених 550 циклів навчання значення функції втрат зменшилося з 0,00117 до 0,000691 (табл. 1), що може бути підтвердженням швидкого навчання нейронної мережі.

Після етапу навчання перевіримо, як створена нейронна мережа буде видаляти наявний адитивний шум, і цю ефективність проаналізуємо на основі отриманих результатів показників на основі формул (1) та (2). Для цього етапу також сформуємо програмний код у середовищі Matlab. Додатково залучимо під час роботи мережі високопродуктивний графічний процесор. На рис. 3 наведемо результат роботи нейронної мережі за значення дисперсії шуму  $\sigma = 10$ . У рамках експерименту для вибраної мережі будемо змінювати значення інтенсивності шуму в межах:  $\sigma = 10, 15, 20, 25$ .

У табл. 2 наведено інші результати роботи створеної нейронної мережі, причому визначено метрики до роботи мережі ( $PSNR_1$ ) та після ( $PSNR_2$ ). Додатково визначено й індекс структурної подібності на основі формули (2).

За результатами отриманих даних із табл. 2 слід відзначити такі характерні особливості роботи створеної нейронної мережі. По-перше, за збільшення значення дисперсії шуму значення метрики  $PSNR_2$  потрохи зменшується. Цей факт означає, що нейронна мережа адекватно реагує на зміну шуму у вихідному зображенні, і для отримання кращих результатів, можливо, необхідно збільшити вибірку тестових зображень на етапі навчання цієї мережі. По-друге, якщо порівняти між собою отримані метрики на основі співвідношення (1) і даних табл. 2, то можна дійти висновку, що нейронна мережа ефективно працює, адже  $PSNR_2$  у середньому на 4–5 дБ є біль-




Рис. 2. Графічна залежність кривої сходження нейронної мережі

Таблиця 1

Значення функції втрат під час навчання нейронної мережі

Кількість циклів	1	50	100	150	200	250	300	350	400	450	500	550	600
$Loss_1$	0,45	0.005	0.003	0.0021	0.00177	0.00156	0.00141	0.00132	0.00126	0.00122	0.00119	0.00117	0.00114
$Loss_2$	0,2205	0.00347	0.00175	0.001283	0.001045	0.0009	0.00084	0.00079	0.000758	0.000731	0.000709	0.000691	0.000674



а) зображення з шумом

б) результат роботи мережі з видалення шуму

Рис. 3. Результат роботи нейронної мережі за  $\sigma = 10$

Параметри якості роботи нейронної мережі

$\sigma$	$PSNR_1$	$PSNR_2$	$SSIM$
10	36,13 дБ	47,16 дБ	0,9953
15	36,54 дБ	44,35 дБ	0,9922
20	36,77 дБ	42,28 дБ	0,9883
25	37,03 дБ	40,57 дБ	0,9836

шою за значення  $PSNR_1$  за різних значень дисперсії шуму. По-третє, за отриманими значеннями індексу структурної подібності (табл. 2) можна підкреслити його наближення до 1, тобто цим у тому числі визначається якість роботи нейронної мережі, яка виражається у тому, що під час обробки зберігаються найменші деталі зображення і не додається розмитість.

**Висновки.** У роботі розглянуто питання створення нейронної мережі згорткового типу для вирішення завдання зменшення адитивного білого шуму в кольоровому зображенні. Зазначено, що існуючі класичні підходи та методи не дають змоги повною мірою вирішити якісно завдання зменшення шуму у разі, коли рівень самого шуму може змінюватися. Окрім того, може проявлятися обмеження в ресурсних можливостях під час використання цих методів. Розроблено архітектуру нейронної мережі та визначено параметри, за якими можна оцінити її ефективність. Додатково реалізовано етап навчання та етап тренування цієї мережі. Отримано, що на етапі навчання мережа показує високі показники, що дає змогу адаптувати її у майбутньому для роботи зі складними зображеннями, які перенасичені деталями та визначаються високою роздільною здатністю. Проведений режим експерименту з тренування нейронної мережі показав, що мережа ефективно видаляє адитивний білий шум. Наприклад, для рівня дисперсії шуму  $\sigma = 15$  ефективність становила приблизно 8 дБ для метрики пікового відношення «сигнал – шум». Наведені результати дослідження можуть бути використані у подальшому для інших застосувань у системах технічного зору, зокрема під час вирішення завдань аналізу зображень в електронних системах відеоспостереження.

#### ЛІТЕРАТУРА

- Li, Z. Image Denoising based on Deep Learning. *Highlights in Science, Engineering and Technology* 39, 1245–1251 (2023). URL: <https://doi.org/10.54097/hset.v39i.6749>.
- Hajipour, K., Mehrdad, V. Edge detection of noisy digital image using optimization of threshold and self organized map neural network. *Multimed Tools Appl* 80, 5067–5086 (2021). URL: <https://doi.org/10.1007/s11042-020-09942-y>.
- Kalare, K., Bajpai, M., Sarkar, S. et al. Deep neural network for beam hardening artifacts removal in image reconstruction. *Appl Intell* 52, 6037–6056 (2022). URL: <https://doi.org/10.1007/s10489-021-02604-y>.
- Kaji, S., Kida, S. Overview of image-to-image translation by use of deep neural networks: denoising, super-resolution, modality conversion, and reconstruction in medical imaging. *Radiol Phys Technol* 12, 235–248 (2019). URL: <https://doi.org/10.1007/s12194-019-00520-y>.
- Murugesan, K., Balasubramani, P. & Murugan, P.R. A quantitative assessment of speckle noise reduction in SAR images using TLFFBP neural network. *Arab J Geosci* 13, 35 (2020). URL: <https://doi.org/10.1007/s12517-019-4900-4>.
- Gowthami, S., Harikumar, R. Conventional neural network for blind image blur correction using latent semantics. *Soft Comput* 24, 15223–15237 (2020). URL: <https://doi.org/10.1007/s00500-020-04859-y>.
- Singh, P., Shankar, A. A novel optical image denoising technique using convolutional neural network and anisotropic diffusion for real-time surveillance applications. *J Real-Time Image Proc* 18, 1711–1728 (2021). URL: <https://doi.org/10.1007/s11554-020-01060-0>.
- Qian, Y., Dong, J., Wang, W. et al. Feature learning for steganalysis using convolutional neural networks. *Multimed Tools Appl* 77, 19633–19657 (2018). URL: <https://doi.org/10.1007/s11042-017-5326-1>.
- Zhang, K., Zuo, W., Chen, Y. et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. *IEEE Transactions on Image Processing* 26, 7, 3142–3155 (2017). URL: <https://doi.org/10.1109/TIP.2017.2662206>.
- Liu, G., Dang, M., Liu, J. et al. True wide convolutional neural network for image denoising. *Information Sciences*, 610, 171–184 (2022). URL: <https://doi.org/10.1016/j.ins.2022.07.122>.
- Lan, R., Zou, H., Pang, C. et al. Image denoising via deep residual convolutional neural networks. *SIVIP* 15, 1–8 (2021). URL: <https://doi.org/10.1007/s11760-019-01537-x>.
- K. Joshi, R. Yadav and S. Allwadhi, «PSNR and MSE based investigation of LSB», 2016 *International Conference on Computational Techniques in Information and Communication Technologies (ICCTICT)*, 2016.

## PECULIARITIES OF USING NEURAL NETWORKS IN THE TASKS OF DIGITAL IMAGE NOISE REDUCTION

### Oleksii Pereverziev

Postgraduate Student at the Department of Acoustic and Multimedia Electronic Systems

National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute", 37 Beresteyskyi ave., Kyiv, Ukraine, 03056

ORCID: 0000-0002-8208-3449

### Kyrylo Trapezon

Candidate of Technical Sciences, Associate Professor, Associate Professor at the Department of Acoustic and Multimedia Electronic Systems

National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute", 37 Beresteyskyi ave., Kyiv, Ukraine, 03056, kirill.trapezon@gmail.com

ORCID: 0000-0001-5873-9519

**Purpose.** The aim of the work is to develop an architecture of an end-to-end convolutional deep neural network for reducing additive white noise in full-color images with a residual learning strategy. **Methodology.** The article presents analytical dependencies for determining the qualitative parameters of a neural network. The practical part includes the software framework and algorithms of machine learning systems based on the instrumental procedures of the Matlab environment. **Findings.** A convolutional neural network scheme was developed to perform procedures for reducing additive white noise in images. The stage of training and training of the neural network is carried out. It was found that the developed neural network allows to increase the peak value of the signal-to-noise ratio in the image by an average of 4-5 dB at different values of noise variance. **Originality.** The developed convolutional neural network is characterized by low values of the loss function after training two test images and allows obtaining a high structural similarity index. The determined network parameters allow for efficient and fast image noise reduction procedures without loss of detail and in the absence of blurring of elements. **Practical value.** The presented results of the study, due to the obtained confirmation of the qualitative work of the neural network, can be used in the future not only to reduce noise in images of various structures, but also for other applications in technical vision systems, in particular, in solving problems of image analysis in electronic video surveillance systems. **Conclusions.** The architecture of the neural network was developed and the parameters by which its effectiveness can be assessed were determined. Additionally, the training stage and the stage of training of this network were implemented. The experiment mode of the neural network training showed that the network effectively removes additive white noise. For example, for the noise variance level, the efficiency was approximately 8 dB for the peak signal-to-noise ratio metric.

**Key words:** network, image, algorithm, noise, layer, convolution, analysis, model.

### REFERENCES

1. Li, Z. Image Denoising based on Deep Learning. *Highlights in Science, Engineering and Technology* 39, 1245–1251 (2023). URL: <https://doi.org/10.54097/hset.v39i.6749>.
2. Hajipour, K., Mehrdad, V. Edge detection of noisy digital image using optimization of threshold and self organized map neural network. *Multimed Tools Appl* 80, 5067–5086 (2021). URL: <https://doi.org/10.1007/s11042-020-09942-y>.
3. Kalare, K., Bajpai, M., Sarkar, S. et al. Deep neural network for beam hardening artifacts removal in image reconstruction. *Appl Intell* 52, 6037–6056 (2022). URL: <https://doi.org/10.1007/s10489-021-02604-y>.
4. Kaji, S., Kida, S. Overview of image-to-image translation by use of deep neural networks: denoising, super-resolution, modality conversion, and reconstruction in medical imaging. *Radiol Phys Technol* 12, 235–248 (2019). URL: <https://doi.org/10.1007/s12194-019-00520-y>.
5. Murugesan, K., Balasubramani, P. & Murugan, P.R. A quantitative assessment of speckle noise reduction in SAR images using TLFFBP neural network. *Arab J Geosci* 13, 35 (2020). URL: <https://doi.org/10.1007/s12517-019-4900-4>.
6. Gowthami, S., Harikumar, R. Conventional neural network for blind image blur correction using latent semantics. *Soft Comput* 24, 15223–15237 (2020). URL: <https://doi.org/10.1007/s00500-020-04859-y>.
7. Singh, P., Shankar, A. A novel optical image denoising technique using convolutional neural network and anisotropic diffusion for real-time surveillance applications. *J Real-Time Image Proc* 18, 1711–1728 (2021). URL: <https://doi.org/10.1007/s11554-020-01060-0>.
8. Qian, Y., Dong, J., Wang, W. et al. Feature learning for steganalysis using convolutional neural networks. *Multimed Tools Appl* 77, 19633–19657 (2018). URL: <https://doi.org/10.1007/s11042-017-5326-1>.
9. Zhang, K., Zuo, W., Chen, Y. et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for

Image Denoising. *IEEE Transactions on Image Processing* 26, 7, 3142–3155 (2017). URL: <https://doi.org/10.1109/TIP.2017.2662206>.

10. Liu, G., Dang, M., Liu, J. et al. True wide convolutional neural network for image denoising. *Information Sciences*, 610, 171–184 (2022). URL: <https://doi.org/10.1016/j.ins.2022.07.122>.

11. Lan, R., Zou, H., Pang, C. et al. Image denoising via deep residual convolutional neural networks. *SIViP* 15, 1–8 (2021). URL: <https://doi.org/10.1007/s11760-019-01537-x>.

12. K. Joshi, R. Yadav and S. Allwadh, «PSNR and MSE based investigation of LSB», 2016 *International Conference on Computational Techniques in Information and Communication Technologies (ICCTICT)*, 2016.

*Стаття надійшла 09.06.2023*