

МОДИФІКОВАНА МОДЕЛЬ ФІЛЬТРАЦІЇ ШУМУ НА ЗОБРАЖЕННЯХ НА ОСНОВІ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ З ДОДАВАННЯМ РЕЗИДУАЛЬНИХ ЗВ'ЯЗКІВ І МОДУЛЮ УВАГИ

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Вступ

Однією з проблем у відновленні зображень, пошкоджених *SAP* шумом є нерівномірний характер розподілу цього шуму. У випадку однорідних плям або темного фону зі «спалахами» яскравих точок традиційні підходи працюють не так надійно. Як наслідок, залишаються або спотворені фрагменти важливої структури, або, навпаки, частина шумових артефактів не відфільтровується повністю.

Відсутність універсальних підходів, здатних ефективно обробляти нерівномірний розподіл шуму *SAP*, призводить до того, що при знешумленні часто залишається спотворена структура зображення або не до кінця відфільтровані артефакти. Це особливо актуально у сферах, де потреба в високій точності зображення критична, зокрема в медичній діагностиці, де навіть незначна втрата деталей може вплинути на точність аналізу. На додачу, існуючі глибокі моделі згорткових нейронних мереж здебільшого орієнтовані на гаусівський шум, тоді як *SAP* шум вимагає спеціалізованих рішень. Саме тому було обрано існуючу модель, яка видаляє наявний на зображенні шум і запропоновано модифікацію, яка покращує результати обробки задля збереження тонких деталей, країв і структури, які важливі для аналізу і діагностики.

Резидуальні з'єднання та Механізми Уваги в Глибоких Моделях

Однією з ключових складових модифікованої моделі є резидуальні з'єднання або так звані *skip connections*, вперше запропоновані в [1-2, 7]. Ідея полягає в тому, щоб додавати сигнал на вході до виходу згорткового блоку, що дає змогу спростити поширення похибки під час зворотного поширення і підвищити глибину мережі без ризику затухання або вибуху градієнтів. Це значно полегшує навчання глибоких моделей та покращує їх здатність до узагальнення. У контексті денойзингу зображень, резидуальні з'єднання дозволяють краще зберігати деталі, оскільки модель не втрачає первинні ознаки, намагаючись водночас відфільтрувати шум. Для шуму *SAP* особливо важливо не втрачати первинні деталі зображення, адже зашумлені пікселі можуть бути критичною частиною текстури або контуру об'єкта. Резидуальні з'єднання допомагають мережі зберегти інформацію про початкові значення, тоді як внутрішні згортки зосереджені на усуненні яскравих артефактів. Як наслідок, модель лише коригує шуми, що підтверджено дослідженнями по глибинному денойзингу [2, 7].

CBAM (Convolutional Block Attention Module) – один із популярних методів, що поєднує два типи уваги [3-5]:

- Канальна увага (*Channel Attention*): визначає, які характеристики зображення є найбільш важливими, і

підсилює їх. Наприклад, якщо мережа обробляє МРТ-знімок, вона може акцентувати увагу на структурах, що важливі для аналізу, і зменшити вплив фону.

- Просторова увага (*Spatial Attention*): допомагає мережі зосередитися на певних областях зображення, які містять корисну інформацію.

Це означає, що важливіші ділянки отримують більшу вагу, а другорядні – меншу. У традиційних нейромережах всі частини зображення обробляються однаково, незалежно від того, наскільки вони важливі. Механізми уваги дозволяють адаптивно керувати цим процесом, фокусуючись на ключових особливостях. Це допомагає краще відновлювати зображення, видаляти шум і покращувати результати моделі.

Модифікована модель видалення шуму

В процесі експериментів з оригінальною моделлю [6] було виявлено, що модель гірше справляється з зображеннями, які містять однорідні плями. Саме тому було прийнято рішення сконцентруватися на покращенні в цій області. Після дослідження існуючих робіт по видаленню шуму, було проведено експерименти з додаванням різних блоків у *SeConvNet* модель. У модифікованій версії зберігається вся концепція *SeConv*-блоків і фінального шару, але додається два ключові вдосконалення у серединні згорткових шарів рис 1.

В модель додано додатковий блок, який поєднує в собі резидуальні з'єднання та механізми *Channel* і *Spatial* уваги. Його основне призначення – точніше відфільтрувати *SAP* шум і водночас зберігати краї, текстури та тонкі переходи яскравості (градієнти), які визначають форму або структуру об'єктів

В основі блоку лежать:

- Резидуальні зв'язки (*skip connections*) [7].
- Модуль уваги (спочатку *Channel Attention*, потім *Spatial Attention* – відомий як *CBAM*) [3-5].

Поєднання резидуальних зв'язків і двох типів уваги (*Channel + Spatial*) в одному блоці (*CBAM*) вибірково підсилює найбільш інформативні канали та фрагменти зображення. Завдяки цьому мережа краще розрізняє шум від реальних структур, що дає змогу зменшити яскраві плями й водночас зберегти чіткі краї та тонкі деталі.

Ідея резидуального зв'язку запозичена з мереж *ResNet*. Він дає змогу поєднати вихід згорткових шарів із початковою версією сигналу, що зменшує ризик «затухання» або «вибуху» під час навчання, полегшуючи корекцію помилок і пришвидшуючи збіжність.

Наступним важливим елементом є *Channel Attention*. Його реалізовано через глобальне усереднення результату після резидуального додавання (*Global Average Pooling*) і двошаровий перцептрон (із активаціями *ReLU* та *sigmoid*). Отримані коефіцієнти масштабують кожен канал так, що найбільш корисні для видалення шуму та відновлення тонких деталей посилюються, а менш суттєві – приглушуються. Завдяки цьому вдається краще відтворити контури та зберігати важливі структури зображення

Далі, для визначення області, де саме слід зосередити увагу на зображенні, додається *Spatial Attention*. Цей модуль спочатку обчислює усереднення (*Average Pooling*) і максимум (*Max Pooling*) по каналах, утворюючи просторову карту з двома шарами. Потім 7×7 -згортка з активацією *sigmoid* формує маску, яка вказує, наскільки сильно слід посилити або послабити кожен піксель. У результаті фрагменти з високою концентрацією шуму чи важливими деталями підкреслюються, а другорядні ділянки стають менш вираженими. Загалом, поєднання *Channel* та *Spatial Attention* у єдиному блоці *CBAM* дає можливість вибірково керувати інформацією в різних областях зображення, чим сприяє більш точному усуненню шумових плям і збереженню візуально важливих елементів.




Рис. 1. Архітектура запропонованої модифікованої моделі, де зеленим кольором виділено доданий блок

Експериментальні дослідження процедури видалення шуму із застосуванням запропонованої моделі

У межах експериментального дослідження було проведено серію випробувань для перевірки ефективності видалення шуму *SAP* із використанням запропонованої модифікованої моделі. Зазначимо, що через обмежені обчислювальні потужності (ноутбук із процесором без підтримки прискореного *GPU*-обчислення) довелося зменшити кількість епох та кроків на епоху порівняно з оригінальним налаштуванням, описаним у базовій статті. Зокрема, було обрано 10 епох і 10 кроків кожна, і такий результат для оригінальної версії *SeConvNet* [6] був прийнятий за еталон (базовий рівень для порівняння).

Додатково слід відзначити, що в оригінальній роботі використовувався інший набір даних. Натомість для даної роботи використано набір МРТ-знімків, який відрізняється як у плані контрасту та текстури, так і за наявністю специфічних шумових артефактів типу «білі плями» на однорідному фоні.

Критерії оцінювання результатів досліджень

Peak signal-to-noise ratio (PSNR) [5] широко використовується для оцінки ефективності різних методів зниження рівня шуму. Вище значення *PSNR* вказує на те, що очищене від шуму зображення, в цілому, ближче до оригінального зображення та має вищу візуальну якість [8].

У своїй роботі ми використовували *PSNR* для оцінки якості відновлених зображень після обробки за допомогою нашої моделі. Високе значення *PSNR* свідчило про те, що зображення після відновлення має малу втрату якості порівняно з оригіналом. В цілому, критерій допомагає отримати об'єктивну оцінку ефективності методу зниження рівня шуму та його впливу на якість зображення.

Результати експериментів

Порівняння візуальних результатів свідчить, що для тестових зображень з рівномірними або не надто контрастними ділянками показники *PSNR* і візуальна якість залишилися приблизно на тому ж рівні, що й в оригінальній *SeConvNet*. На рис. 2-9 (а, б, с) наведено приклади відновлення фрагментів МРТ-знімків, де модифікована модель демонструє схожу з базовою

якість. Перше зображення (а) – оригінальний МРТ знімок з датасету. Друге зображення (б) – це результат роботи оригінальної моделі з видалення шуму. Третє зображення (с) – результат роботи модифікованої моделі. Як видно з таблиці 1, значення *PSNR* коливається в межах похибки і ми не

можемо говорити про значне покращення моделі. На рис. можна побачити порівняння оригінального зображення з зображенням після знешумлення після роботи оригінальної моделі і на рис після модифікованої моделі.




Рис. 2. Результати роботи моделі при рівні шуму 95%.

(а) – оригінальне зображення, (б) – оригінальна модель, (с) – модифікована модель




Рис. 3. Порівняння результатів роботи моделей при рівні шуму 95%. (а) – оригінальне зображення з оригінальною моделлю, (б) – оригінальне зображення з модифікованою моделлю




Рис. 4. Результати роботи моделі при рівні шуму 95%. (а) – оригінальне зображення, (б) – оригінальна модель, (с) – модифікована модель




Рис. 5. Порівняння результатів роботи моделей при рівні шуму 95%. (а) – оригінальне зображення з оригінальною моделлю, (б) – оригінальне зображення з модифікованою моделлю

Водночас, для окремих МРТ-знімків з датасету, які від початку характеризувалися значною кількістю білих плям (які можна розглядати як сплески *SAP* шуму на

темному тлі), модифікований варіант *SeConvNet* дає кращий результат. Це помітно за числовими метриками з таблиці 1 (*PSNR* зростає на 6-7%).




Рис. 6. Результати роботи моделі при рівні шуму 95%. (а) – оригінальне зображення, (б) – оригінальна модель, (с) – модифікована модель




Рис. 7. Порівняння результатів роботи моделей при рівні шуму 95%. (а) – оригінальне зображення з оригінальною моделлю, (б) – оригінальне зображення з модифікованою моделлю




Рис. 8. Результати роботи моделі при рівні шуму 95%.
(а) – оригінальне зображення, (б) – оригінальна модель, (с) – модифікована модель




Рис. 9. Порівняння результатів роботи моделей при рівні шуму 95%. (а) – оригінальне зображення з оригінальною моделлю, (б) – оригінальне зображення з модифікованою моделлю

Таблиця 1. Результати роботи моделей по зображенням

	Оригінальна модель (PSNR)	Модифікована модель (PSNR)
Рис 1	33.3544	33.4602 (+0.32%)
Рис 2	32.5169	32.3282 (-0.58%)
Рис 3	33.8099	36.6409 (+8.37%)
Рис 4	32.4026	34.1733 (+5.46%)

покращення на найбільш складних прикладах зі значними яскравими Висновки і перспективи подальших досліджень

За результатами проведених експериментів можна зробити декілька висновків щодо ефективності модифікованої

моделі *SeConvNet* у задачі видалення *SAP* шуму на прикладі МРТ-знімків. Для частини досліджуваних зображень із рівномірними фрагментами чи помірним рівнем артефактів показники *PSNR* та *SSIM*, а також візуальні характеристики відновлених знімків, залишаються приблизно на рівні оригінальної моделі. Зокрема, з таблиці 1 видно, що різниця у значеннях *PSNR* на кількох зображеннях складає лише ~0.3–0.6%, що можна вважати похибкою при навчанні. Водночас у низці випадків модифікована модель демонструє помітне зростання *PSNR* (5–8%) і, відповідно, кращу якість відновлення зображення. Ідеться про МРТ-знімки, які містять великі контрастні плями шуму.

Навіть за скороченої кількості епох та ітерацій тренування, додатковий блок (поєднання резидуальних зв'язків із механізмом уваги) продемонстрував плямами

на зображенні. Це свідчить, що модель успішно вчиться приділяти більше уваги ділянкам із найсильнішим шумом і ретельніше відновлювати відповідні пікселі.

Для розширення даного дослідження в майбутньому планується збільшити кількість тренувальних епох, аби перевірити потенціал модифікованої моделі та досягти ще більших показників точності, а також поекспериментувати з різними параметрами модифікованої моделі.

Література

1. He K. et al. Deep Residual Learning for Image Recognition. URL: <https://arxiv.org/pdf/1512.03385v1>.
2. Zhang K. et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. URL: <https://ieeexplore.ieee.org/document/7839189>.
3. Lu T. et al. Autoencoder Combined with CBAM Improves Denoising of MR Images. URL: <https://ieeexplore.ieee.org/document/9750433>.
4. Woo S. et al. CBAM: Convolutional Block Attention Module. URL: <https://arxiv.org/pdf/1807.06521v2>.
5. Cai G. CBAM-DnCNN: An Improved Method For Image Denoising. URL: <https://www.computer.org/csdl/proceedings-article/eiecs/2023/10435545/1UIC6jLXz0Y>.
6. Rafiee A. A., Farhang M. A deep convolutional neural network for salt-and-pepper noise removal using selective convolutional blocks. URL: <https://arxiv.org/pdf/2302.05435v1>.
7. Wang T., Hu Z., Guan Y. An efficient lightweight network for image denoising using progressive residual and convolutional attention feature fusion. URL: <https://www.nature.com/articles/s41598-024-60139-x>.
8. Линовський А. О., Мухін В. Є. Модифікована модель фільтрації шуму на зображеннях на основі згорткової нейронної мережі. *Кибербезпека: освіта, наука, техніка*. 2024. № 4(24). С. 388–397. URL: <https://csecurity.kubg.edu.ua/index.php/journal/article/view/634>.

Мухін В.Є., Линовський А.О.

МОДИФІКОВАНА МОДЕЛЬ ФІЛЬТРАЦІЇ ШУМУ НА ЗОБРАЖЕННЯХ НА ОСНОВІ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ З ДОДАВАННЯМ РЕЗИДУАЛЬНИХ ЗВ'ЯЗКІВ І МОДУЛЮ УВАГИ

У багатьох прикладних задачах обробки зображень – від технічної діагностики до медичної візуалізації – критичним є якісне відновлення зображень, що зазнали сильного Salt and Paper (SAP) шуму. Такий тип шуму призводить до появи поодиноких, але вкрай яскравих (білих) або темних (чорних) пікселів, які можуть суттєво спотворювати візуальну картину та ускладнювати подальший аналіз. У цій роботі пропонується модифікація існуючої згорткової нейронної мережі SeConvNet, призначеної для видалення SAP шуму. Основною метою дослідження є покращення обробки зображень із вираженими білими плямами, де оригінальна модель SeConvNet виявилася менш ефективною. Запропонована модифікація полягає у додаванні блока, що об'єднує резидуальні зв'язки й механізми каналної та просторової уваги (Channel+Spatial Attention). Це поєднання, відоме як CBAM (Convolutional Block Attention Module). Даний блок дає змогу підсилити інформативні канали та найбільш критичні зони зображення, що покращує видалення висококонтрастних плям шуму і водночас зберігає дрібні деталі.

Результати дослідження продемонстрували приріст якості відновлення на окремих групах зображень, особливо тих, де зашумлені ділянки мали велику інтенсивність яскравих плям у 5-8%. Досліди проводилися на МРТ-знімках, що підтвердило ефективність підходу в умовах складних текстур і специфічних артефактів шуму. Значущість цих результатів полягає у можливості інтегрування модифікованої SeConvNet у застосування медичної діагностики та інші сфери, де точне збереження дрібних структур

зображення є критично важливим. Попри обмежені обчислювальні ресурси, запроваджені вдосконалення дозволили досягти підвищення ефективності видалення SAP шуму, що свідчить про високий потенціал розвитку даного підходу в майбутніх дослідженнях.

Ключові слова: залишкова нейронна мережа; нейронні мережі; згорткова нейронна мережа; SAP шум; покращення зображень.

Mukhin V.Y., Lynovskyi A.O.

MODIFIED MODEL OF NOISE FILTERING IN IMAGES BASED ON CONVULSIVE NEURAL NETWORK WITH THE ADDITION OF RESIDUAL CONNECTIONS AND ATTENTION MODULE

In numerous applied image processing tasks, ranging from technical diagnostics to medical imaging, the accurate restoration of images affected by severe salt-and-pepper (SAP) noise is of critical importance. This type of noise introduces isolated but highly intense white or black pixels, which can significantly distort the visual representation and complicate subsequent analysis.

This study presents a modification of the existing SeConvNet convolutional neural network, specifically designed to enhance SAP noise removal. The primary objective is to improve the processing of images with prominent white noise artifacts, where the original SeConvNet model has demonstrated suboptimal performance. The proposed modification incorporates a novel block that combines residual connections with both channel and spatial attention mechanisms (Channel+Spatial Attention). This integration, implemented through the Convolutional Block Attention Module (CBAM), enables the network to emphasize informative channels and critical spatial regions, thereby enhancing the suppression of high-contrast noise artifacts while preserving fine structural details.

Experimental results indicate a notable improvement in image restoration quality, particularly in datasets where noise-affected regions exhibited a high intensity of bright spots within a 5–8% range. The proposed approach was evaluated on MRI scans, confirming its efficacy in handling complex textures and domain-specific noise artifacts. The significance of these findings lies in the potential integration of the enhanced SeConvNet into medical diagnostic applications and other fields where the precise preservation of fine image structures is paramount.

Despite computational constraints, the introduced modifications have led to improved SAP noise suppression, underscoring the strong potential of this approach for further research and practical implementations.

Keywords: neural networks; CNN; SeConvNet; SAP noise; image enhancement; residual neural network.