

УДК 519.2

DOI [https://doi.org/10.24144/2616-7700.2025.47\(2\).278-288](https://doi.org/10.24144/2616-7700.2025.47(2).278-288)**Ю. О. Товт¹, А. Ю. Брила²**

¹ ДВНЗ «Ужгородський національний університет»,
аспірант кафедри системного аналізу та теорії оптимізації
yurii.tovt@uzhnu.edu.ua
ORCID: <https://orcid.org/0009-0000-9556-0630>

² ДВНЗ «Ужгородський національний університет»,
доцент кафедри системного аналізу та теорії оптимізації,
кандидат фізико-математичних наук, доцент
andrii.bryla@uzhnu.edu.ua
ORCID: <https://orcid.org/0000-0003-2518-9877>

ФІЛЬТРАЦІЯ СПЕКЛ-ШУМУ НА УЛЬТРАЗВУКОВИХ ЗОБРАЖЕННЯХ ЗА ДОПОМОГОЮ КОМПЛЕКСНОЗНАЧНИХ НЕЙРОННИХ МЕРЕЖ

Ультразвукові зображення широко застосовуються в багатьох галузях. Їх аналіз є надзвичайно важливою задачею, тому фільтрація шуму на таких зображеннях відіграє важливу роль. У цій роботі розглянуто фільтрацію спекл-шуму на ультразвукових зображеннях за допомогою комплекснозначних нейронних мереж. Проведено експерименти з фільтрації шуму та порівняння отриманих результатів із деякими відомими методами фільтрації спекл-шуму.

Ключові слова: нейронні мережі, комплекснозначні нейронні мережі, цифрові зображення, фільтрація шуму, спекл-шум.

1. Вступ. Однією з основних перепон для успішної обробки та аналізу цифрових зображень є наявність шуму. Тому фільтрація шуму була і залишається одним із основних напрямів досліджень у галузі цифрової обробки зображень. Зазвичай виділяють такі типи шуму: адитивний (зазвичай із гаусівським розподілом), мультиплікативний (спекл) та імпульсний. Серед цих типів шуму особливу увагу привертає мультиплікативний шум, який є характерним для когерентних систем, таких як ультразвук. Ця стаття присвячена фільтрації мультиплікативного шуму на ультразвукових зображеннях за допомогою нейронних мереж. Спекл-шум спостерігається на зображеннях, отриманих за допомогою когерентних джерел випромінювання (наприклад, лазера, радара або ультразвуку), і проявляється у вигляді зернистої структури, що знижує контраст та ускладнює візуальне сприйняття і подальший аналіз зображення. Причиною появи спеклів є мікроскопічні нерівності поверхні в межах одного пікселя. Коли когерентне випромінювання потрапляє на таку поверхню та відбивається, прийнятий сигнал зазнає випадкових коливань фази й амплітуди [1]. З часу становлення обробки цифрових зображень як окремої галузі науки було створено низку алгоритмів, що дозволяють фільтрувати спекл-шум. До одних із перших запропонованих алгоритмів можна віднести фільтри Lee [2] та Frost [3]. Ці фільтри використовують локальні статистичні характеристики фрагмента зображення для обчислення оновленого значення інтенсивності цільового пікселя. Наприклад, фільтр Lee використовує локальне середнє значення та вагові коефіцієнти, які базуються на локальній і глобальній дисперсії зображення, для

розрахунку інтенсивності пікселя. Фільтр Frost, своєю чергою, застосовує експоненційно зважене значення, причому ваги обчислюються на основі локальної дисперсії та середнього значення.

Іншим класичним підходом, який може бути застосований для фільтрації спекл-шуму, є фільтр VM3D [4]. Цей фільтр відрізняється інноваційним підходом до фільтрації шуму, який включає обробку як у просторовій, так і у частотній області. Статистично схожі фрагменти зображення формують 3D-блоки, після чого ці блоки обробляються у частотній області шляхом використання тривимірного перетворення Фур'є. Завдяки цьому, VM3D демонструє високу якість фільтрації і вважається одним із найефективніших фільтрів, розроблених на даний момент.

Сьогодні, з існуючим рівнем обчислювальних потужностей, нейронні мережі все частіше використовуються для розв'язання задач у різних сферах. Так, у [5] [6] багатопартийний перцептрон (MLP) був успішно використаний для фільтрації адитивного гаусівського та змішаного (пуасонівського та гаусівського) шуму. Для фільтрації зображення розбивали на невеликі фрагменти, які оброблялися MLP, після чого відбувалася реконструкція зображення. Такий підхід продемонстрував результати фільтрації, які є близькими до отриманих за допомогою фільтра VM3D, а в деяких випадках - кращими.

Висока популярність згорткових нейромереж (CNN), закономірно призвела до великої кількості досліджень, у яких цей тип нейромереж використовувався для фільтрації шуму на цифрових зображеннях. Так, у [7–9] CNN застосовувалися для фільтрації різних видів шуму. Зокрема, Hybrid CNN [10] та Pre-trained RLN [11] використовувалися для фільтрації спекл-шуму на ультразвукових зображеннях та продемонстрували результати, які в деяких випадках перевершували результати класичних фільтрів (наприклад, Lee та Frost).

У нашій роботі ми застосовували алгоритм фільтрації, запропонований у [12], для фільтрації спекл-шуму на ультразвукових зображеннях. Цей алгоритм здійснює обробку зображень у частотній області з допомогою комплекснозначної нейронної мережі, з метою ефективного зменшення спекл-шуму.

2. Основний результат.

2.1. Ультразвукові зображення та спекл-шум. Як описано у [13], процес утворення ультразвукового зображення (В-режим) загалом зводиться до променеутворення (beamforming), яке є методом обробки відбитих ехо-сигналів. Ультразвуковий датчик отримує від тканин множинні радіочастотні (RF) ехо-сигнали, які називаються каналними сигналами. Для формування зображення використовується метод «затримка та сума» (Delay-and-Sum, DAS), під час якого до кожного каналного сигналу застосовуються спеціально розраховані часові затримки, щоб скомпенсувати різний час поширення звуку до певної фокальної точки. Після синхронізації фаз ці затримані сигнали підсумовуються, що когерентно посилює сигнал саме з фокальної точки, пригнічуючи шум з інших областей. Повторення цього процесу для всіх точок сканування генерує повне зображення. Для підвищення роздільної здатності та контрастності сучасні системи часто використовують адаптивні методи променеутворення (наприклад, DMAS або методи на основі когерентності), які додатково оптимізують цей процес.

Спекл-шум є невід'ємною частиною ультразвукових зображень. Серед основ-

них причин його появи є неоднорідна структура тканин, багаторазові відбиття ехо-сигналів, когерентне інтерференційне накладання хвиль та випадкові флуктуації сигналу.

Для спрощення під час досліджень ми використовували зображення у відтінках сірого. Таке спрощення не зменшує загальності, оскільки кольорові зображення можуть бути представлені як комбінація зображень у відтінках сірого в різних кольорових каналах (наприклад, RGB).

Як відомо, цифрове зображення у просторовій області представляється у вигляді дискретної функції

$$f : D^2 \rightarrow I,$$

де $D = \{1, 2, \dots, N\}$ - просторова область, а $I = \{0, 1, \dots, L - 1\}$ — інтенсивність [14]. При розробці методів фільтрації шуму з метою моделювання спекл-шуму використовують наступний підхід:

$$g(x, y) = f(x, y) + f(x, y)\eta(x, y),$$

де $g(x, y)$ — зашумлене зображення, $f(x, y)$ — ідеальне зображення, $\eta(x, y)$ — рівномірно розподілений випадковий шум. Для моделювання спекл-шуму у цій роботі ми використовували вбудовану функцію MATLAB, яка є стандартним інструментом для генерації мультиплікативного шуму. Варто зазначити, що інтенсивність шуму (його стандартне відхилення) у цій роботі подається у вигляді $c\sigma$, де c — коефіцієнт, а σ — стандартне відхилення ідеального зображення (зображення без шуму). Для оцінки якості фільтрації зображення зазвичай користуються значеннями RMSE

$$\text{RMSE} = \sqrt{\frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N \left(f(x, y) - \hat{f}(x, y) \right)^2},$$

або PSNR

$$\text{PSNR} = 20 \log_{10} \left(\frac{L}{\text{RMSE}} \right),$$

де $f(x, y)$ — оригінальне зображення, $\hat{f}(x, y)$ — відфільтроване зображення, L — максимальне значення інтенсивності пікселя, а $\text{RMSE} > 0$ — середньоквадратичне відхилення.

2.2. Фільтрація спекл-шуму за допомогою комплекснозначних нейронних мереж. Як відомо, шум на цифрових зображеннях зазвичай зосереджується у високих частотах. Тому фільтрацію шуму можна розглядати як спосіб інтелектуального «приглушення» певних високих частот спектру цифрового зображення. Ключовим у цьому процесі є саме інтелектуальна обробка високих частот зображення, оскільки, крім шуму, високі частоти репрезентують дрібні деталі зображення, які можуть бути дуже важливими. Тобто просте «приглушення» високих частот призведе до втрати дрібних деталей на зображенні, що є недопустимим для певних областей, таких як медицина рис. 1.




Рис. 1. (a) Ідеальне зображення. (b) Зашумлене зображення (спекл-шум, 0.4σ) (c) Зашумлене зображення з приглушеними високими частотами.

Саме тому в цій роботі ми користуємося інтелектуальним алгоритмом фільтрації, запропонованим у [12]. Алгоритм базується на використанні комплексно-значної нейромережі (MLMVN) [15] з одним прихованим шаром. З точки зору топології MLMVN наслідує MLP, проте на відміну від останнього базується на багатозначних нейронах (MVN) [16]. Особливістю MVN є те, що входи, вихід та ваги нейрона є комплексними числами. Саме ця особливість нейрона дозволяє здійснювати ефективну обробку цифрового зображення у частотній області. Ефективне використання MVN та MLMVN продемонстровано у різноманітних областях [17–24].

Обробка зображення здійснюється шляхом його розбиття на множину перекриваючихся фрагментів (патчів) та подальшої обробки їх перетворень Фур'є за допомогою MLMVN. Реконструкція фільтрованого зображення здійснюється шляхом об'єднання отриманих патчів у частотній області. Під час обробки перетворень Фур'є фрагментів зображення кожен нейроелемент MLMVN фактично здійснює згортку у частотній області:

$$\mathcal{F}^{-1}(\mathcal{F}(w) \odot \mathcal{F}(p)) = w \star p.$$

Не зважаючи на те, що окремий нейроелемент не породжує фільтрів (як було показано у [25]), комплекснозначна нейромережа в цілому здатна ефективно здійснювати фільтрацію шуму на цифрових зображеннях. Фактично MLMVN здійснює інтелектуальну обробку частот, представлених у спектрі патчу, при якій частоти, що містять шум (переважно високі), приглушуються, але водночас високі частоти, що відповідають дрібним деталям зображення, зберігаються завдяки адаптивному підбору комплексних ваг нейронів, що дозволяє виділити структурну інформацію без втрат деталей.

Можна вважати, що така селективна обробка компонент перетворення Фур'є є результатом процесу навчання, під час якого на вхід нейромережі подаються зашумлені патчі у частотній області, а ідеальні фрагменти у частотній області є бажаними виходами. Оскільки навчальна множина зазвичай складається з великої кількості навчальних зразків, класичний алгоритм навчання зі зворотним поширенням помилки для MLMVN [15] може займати багато часу. Тому для навчання використовувався алгоритм навчання пакетами [26], який дозволяє оновлювати ваги всіх нейронів одночасно для багатьох навчальних зразків.

2.3. Проведені експерименти та отримані результати. Як було зазначено вище, з метою фільтрації спекл-шуму на ультразвукових зображеннях ми використовували алгоритм, запропонований у [12]. Під час наших експериментів ми використовували комплекснозначну нейромережу з топологією 64-1024-64, тобто 64 входи, 1024 нейрони у прихованому шарі та 64 нейрони у вихідному шарі. У нейронах прихованого шару використовувалася класична активаційна функція для MVN з неперервним виходом

$$f(z) = \frac{z}{|z|}.$$

Під час експериментів для нейронів вихідного шару ми використовували такі активаційні функції:

$$f(z) = z, \quad (1)$$

$$f(z) = \begin{cases} z, & |z| \leq 1; \\ \frac{1}{1+e^{-|z|}} e^{i \arg(z)}, & |z| > 1; \end{cases} \quad (2)$$

$$f(z) = \tanh(|z|) e^{i \arg(z)}. \quad (3)$$

Для тренування MLMVN було використано множину з 300 зображень у відтінках сірого. Ця множина була розбита на три підмножини — S_t , S_v та S_f — для формування тренувальної, валідаційної та тестової множин. Важливо зазначити, що для цих підмножин справедливе твердження

$$S_t \cap S_v \cap S_f = \emptyset.$$

Тренувальна множина використовувалася для оновлення ваг нейронів за допомогою алгоритму навчання пакетами. Для побудови тренувальної множини ідеальні зображення були спотворені мультиплікативним шумом, після чого з кожного зображення було вибрано по h фрагментів (патчів) розміру $n \times t$ із просторовими координатами (x_i, y_i) , $i = \overline{1, h}$. Таким чином було сформовано дві множини P^{ideal} та P^{noisy} елементами яких є ідеальні та зешумлені патчі. Після цього було здійснено перехід у частотну область шляхом обчислення прямого двовимірного перетворення Фур'є для кожної пари патчів. З векторизованих перетворень Фур'є було сформовано дві множини наступним чином

$$P_{\mathcal{F}}^{\text{ideal}} = \left\{ \text{vec} \left(\frac{1}{nm} \mathcal{F}(C) \right)^T \mid C \in P^{\text{ideal}} \right\},$$

та

$$P_{\mathcal{F}}^{\text{noisy}} = \left\{ \text{vec} \left(\frac{1}{nm} \mathcal{F}(D) \right)^T \mid D \in P^{\text{noisy}} \right\}.$$

Тренувальна множина була сформована з елементів цих множин наступним чином

$$T = \left\{ (T_i^{\text{in}}, T_i^{\text{out}}) \mid i = \overline{1, lh}, T_i^{\text{in}} \in P_{\mathcal{F}}^{\text{noisy}}, T_i^{\text{out}} \in P_{\mathcal{F}}^{\text{ideal}} \right\},$$

де l — кількість зображень. Під час експериментів, проведених у рамках цієї роботи, для побудови тренувальної множини ми використовували патчі розміру

8×8 . Це дозволило досягти хорошого рівня фільтрації, водночас використовуючи відносно невелику кількість нейронів у нейромережі. З кожного ідеального та зашумленого зображення було вибрано по 200 патчів, таким чином тренувальна множина складалася з 60 000 навчальних зразків. Також варто звернути увагу на попередню обробку патчів як у просторовій, так і у частотній області — йдеться про нормалізацію фрагментів зображень. Цей крок є важливим і загальноприйнятим у галузі машинного навчання, а у нашому випадку він дозволяє уникнути появи надмірно великих значень ваг нейронів у процесі навчання.

Валідаційна та тестова множини склалися із зображень у відтінках сірого. Їхні ролі полягали, відповідно, в оцінці узагальнювальних можливостей MLMVN у процесі навчання (у нашому випадку — після кожного батчу) та у фінальній оцінці якості фільтрації після завершення навчання. Як було зазначено раніше, навчання проводилося за допомогою батчевого алгоритму. Під час наших експериментів кількість навчальних зразків у батчі було вибрано рівною 20 000. Таке рішення було прийнято на основі експериментів, проведених у [12].

Процес навчання на кожному батчі тривав до досягнення бажаного середнього значення PSNR на патчах, що входили до батчу, або до моменту досягнення граничної кількості ітерацій. Навчання тривало до моменту досягнення бажаного рівня PSNR на зображеннях із валідаційної множини. Під час валідації ми здійснювали фільтрацію кожного з цих зображень та обчислювали середнє значення PSNR між ідеальними та відфільтрованими зображеннями.

Розбиття зображення на патчі, фільтрація та реконструкція зображення з отриманих після обробки патчів здійснювалася за алгоритмами, наведеним у [12]. Для зручності читача алгоритм фільтрації подано нижче алг. 1.

Algorithm 1 Процес фільтрації шуму на цифровому зображенні за допомогою MLMVN

Require: I_{noisy} : Зашумлене зображення

Require: m : Довжина патча

Require: n : Висота патча

Ensure: I_{filtered} : Зображення після фільтрації

Procedure:

- 1: Нормалізувати зображення: $\hat{I}_{\text{noisy}} \leftarrow \frac{1}{255} I_{\text{noisy}}$
 - 2: Розбити $\hat{I}_{\text{noisy}}$ на патчі P : $P \leftarrow \text{split}(\hat{I}_{\text{noisy}})$
 - 3: $\tilde{P} \leftarrow \emptyset$
 - 4: **for** $p \in P$ **do**
 - 5: Перейти в частотну область: $p_{\mathcal{F}} \leftarrow \mathcal{F}(p)$
 - 6: Нормалізувати $p_{\mathcal{F}}$: $\hat{p}_{\mathcal{F}} \leftarrow \frac{1}{nm} p_{\mathcal{F}}$
 - 7: Обробити $\hat{p}_{\mathcal{F}}$ з допомогою MLMVN: $\hat{p}_{\mathcal{F}}^{\text{out}} \leftarrow \text{MLMVN}(\hat{p}_{\mathcal{F}})$
 - 8: Відновити коефіцієнт: $\hat{p}_{\mathcal{F}}^{\text{out}}[0, 0] \leftarrow \hat{p}_{\mathcal{F}}[0, 0]$
 - 9: Денормалізувати $\hat{p}_{\mathcal{F}}^{\text{out}}$: $p_{\mathcal{F}}^{\text{out}} \leftarrow (nm) \hat{p}_{\mathcal{F}}^{\text{out}}$
 - 10: Перейти у просторову область: $p^{\text{out}} \leftarrow \mathcal{F}^{-1}(p_{\mathcal{F}}^{\text{out}})$
 - 11: $\tilde{P} \leftarrow \tilde{P} \cup \{p^{\text{out}}\}$
 - 12: **end for**
 - 13: Синтезувати зображення I_{filtered} використовуючи $\tilde{P}$: $I_{\text{filtered}} \leftarrow \text{synthesize}(\tilde{P})$
 - 14: **return** I_{filtered}
-

Нижче, для порівняння, наведено результати фільтрації зашумлених зображень у відтінках сірого, спотворених мультиплікативним спекл-шумом табл. 1, табл. 2 та табл. 3 на різних рівнях, із використанням MLMVN та популярних методів фільтрації. Для фільтра BM3D було розглянуто кілька значень параметра стандартного відхилення шуму, оскільки в реальних задачах ця інформація зазвичай невідома. Для фільтрів Lee та Frost було використано вікно розміром 3×3 , при цьому коефіцієнт демпфування для фільтра Frost встановлено рівним 2. Для фільтрації спекл-шуму застосовувалися нейромережі MLMVN-S-1, MLMVN-S-2 та MLMVN-S-3. У якості активаційних функцій для нейронів вихідного шару використовувалися функції, наведені вище: (1) для MLMVN-S-1, (2) для MLMVN-S-2 та (3) для MLMVN-S-3. Приклади зображень після фільтрації за допомогою MLMVN наведено на рис. 2.

Таблиця 1.

Результати фільтрації зображень спотворених спекл-шумом 0.2σ . Найкращі результати виділено жирним шрифтом.

	Breast1	Carotid1	Kidney1	Liver1	Thyroid1
Original PSNR	37.8908	34.9803	35.5726	41.0108	34.3516
BM3D 0.5σ	39.1399	36.2753	36.5802	40.2705	37.1153
BM3D 1.0σ	35.2463	33.7841	33.7073	35.9412	35.0923
BM3D 1.5σ	32.6594	31.829	31.701	33.6593	33.4208
Frost	31.3314	30.5562	31.665	32.8708	35.0743
Lee	32.8178	31.5633	32.3374	34.1547	35.503
MLMVN-S-1	36.7027	36.2856	36.2822	39.8335	37.5344
MLMVN-S-2	37.7461	36.5851	36.5408	40.559	37.5456
MLMVN-S-3	37.3061	36.4176	36.4244	40.2678	37.4919
	Breast2	Carotid2	Kidney2	Liver2	Thyroid2
Original PSNR	37.1545	34.1198	34.498	33.0663	36.9289
BM3D 0.5σ	38.3667	37.268	35.6017	34.6407	39.5779
BM3D 1.0σ	33.9668	35.5145	33.2245	32.3094	36.8239
BM3D 1.5σ	31.5642	33.3176	31.3852	30.5669	34.2104
Frost	31.2087	34.1096	31.4069	31.078	33.2237
Lee	32.3654	34.6637	31.9982	31.4868	34.1978
MLMVN-S-1	37.0653	37.0107	35.5345	34.7664	37.9344
MLMVN-S-2	37.9244	37.027	35.7039	34.8706	38.591
MLMVN-S-3	37.5665	36.966	35.6325	34.8062	38.323

Таблиця 2.

Результати фільтрації зображень спотворених спекл-шумом 0.3σ . Найкращі результати виділено жирним шрифтом.

	Breast1	Carotid1	Kidney1	Liver1	Thyroid1
Original PSNR	34.4038	31.5317	32.0353	37.5692	30.8371
BM3D 0.5σ	36.2042	33.7832	34.0056	37.3029	34.5605
BM3D 1.0σ	32.6357	31.7486	31.6437	33.6858	33.1924
BM3D 1.5σ	30.8859	30.2808	30.1745	32.0221	31.9262
Frost	31.2019	30.3685	31.4338	32.8152	34.3126
Lee	32.67	31.3301	32.0954	34.0914	34.695
MLMVN-S-1	36.0411	34.7347	34.7348	38.7964	35.4562
MLMVN-S-2	36.4476	34.5783	34.6069	38.9908	34.9621
MLMVN-S-3	36.3014	34.6349	34.659	38.9424	35.15
	Breast2	Carotid2	Kidney2	Liver2	Thyroid2
Original PSNR	33.6098	30.577	30.9806	29.5962	33.4314
BM3D 0.5σ	35.3708	34.4086	33.2315	32.2234	36.7711
BM3D 1.0σ	31.571	33.0454	31.2975	30.4067	34.0443
BM3D 1.5σ	30.0656	31.4221	29.8622	29.1595	32.0451
Frost	31.0708	33.4936	31.0976	30.6715	32.929
Lee	32.207	33.9798	31.6873	31.0717	33.8525
MLMVN-S-1	36.0479	35.169	33.9883	33.0481	36.6263
MLMVN-S-2	36.2173	34.6948	33.8213	32.8745	36.5402
MLMVN-S-3	36.1719	34.8669	33.8785	32.9327	36.5933

Таблиця 3.

Результати фільтрації зображень спотворених спекл-шумом 0.4σ . Найкращі результати виділено жирним шрифтом.

	Breast1	Carotid1	Kidney1	Liver1	Thyroid1
Original PSNR	31.9014	29.0791	29.6252	35.0468	28.3715
BM3D 0.5σ	34.2741	32.2246	32.495	35.4086	33.0611
BM3D 1.0σ	31.2484	30.5735	30.4293	32.4032	32.055
BM3D 1.5σ	29.96	29.4576	29.211	31.0584	31.0142
Frost	31.0133	30.0204	31.0708	32.6608	33.533
Lee	32.41	30.9008	31.6917	33.8938	33.8096
MLMVN-S-1	34.9747	32.8694	32.9661	37.3859	33.286
MLMVN-S-2	34.9264	32.5407	32.7335	37.2349	32.7141
MLMVN-S-3	34.9722	32.669	32.8189	37.3129	32.9332
	Breast2	Carotid2	Kidney2	Liver2	Thyroid2
Original PSNR	31.1092	28.098	28.544	27.1536	30.9558
BM3D 0.5σ	33.4224	32.5799	31.7386	30.7006	34.9141
BM3D 1.0σ	30.3826	31.5738	30.1574	29.3258	32.4533
BM3D 1.5σ	29.2901	30.3258	29.0103	28.319	30.81
Frost	30.8562	32.6695	30.7417	30.1114	32.6181
Lee	31.9637	33.0318	31.3229	30.4737	33.4527
MLMVN-S-1	34.6785	32.993	32.1987	30.965	35.0482
MLMVN-S-2	34.4645	32.4474	31.9774	30.7869	34.6272
MLMVN-S-3	34.5716	32.6546	32.0612	30.8457	34.8008




Рис. 2. (a) — ідеальне зображення, (b) — зашумлене зображення (спекл-шум 0.4σ , PSNR 29.6252dB), (c) — відфільтроване зображення (PSNR 32.9661dB), (d) — ідеальне зображення, (e) — зашумлене зображення (спекл-шум 0.4σ , PSNR 30.9558dB), (f) — відфільтроване зображення (PSNR 35.0482dB), (g) — ідеальне зображення, (h) — зашумлене зображення (спекл-шум 0.4σ , PSNR 27.1536dB), (i) — відфільтроване зображення (PSNR 30.965dB).

3. Висновки та перспективи подальших досліджень. У цій роботі розглянуто задачу фільтрації спекл-шуму на ультразвукових зображеннях із використанням MLMVN. Під час дослідження проведено експерименти з фільтрації спекл-шуму за допомогою комплекснозначної нейронної мережі з використанням різних активаційних функцій на нейронах вихідного шару. Отримані

результати свідчать про те, що MLMVN може бути ефективно застосована для розв'язання подібних задач. Завдяки інтелектуальній фільтрації запропонований підхід дозволяє зменшити рівень шуму на ультразвукових зображеннях, водночас зберігаючи дрібні деталі, що є надзвичайно важливим у таких галузях, як медицина. Це підтверджує потенціал використання нейронних мереж цього типу для розв'язання суміжних задач обробки зображень, зокрема фільтрації інших видів шуму та відновлення дефокусованих зображень.

Список використаної літератури

1. Goodman, J. W. (2000). *Statistical Optics*. Wiley Classics Library ed. New York: Wiley. pp. 347–351.
2. Lee, J.-S. (1980). Digital image enhancement and noise filtering by use of local statistics. *IEEE Trans. Pattern Anal. Mach. Intell.*, PAMI-2, 165–168. <https://doi.org/10.1109/TPAMI.1980.4766994>
3. Frost, V. S., Stiles, J. A., Shanmugan, K. S., & Holtzman, J. C. (1982). A model for radar images and its application to adaptive digital filtering of multiplicative noise. *IEEE Trans. Pattern Anal. Mach. Intell.*, PAMI-4, 157–166. <https://doi.org/10.1109/TPAMI.1982.4767223>
4. Dabov, K., Foi, A., Katkovnik, V., & Egiazarian, K. (2007). Image denoising by sparse 3-D transform-domain collaborative filtering. *IEEE Trans. Image Process.*, 16, 2080–2095. <https://doi.org/10.1109/TIP.2007.901238>
5. Burger, H. C., Schuler, C. J., & Harmeling, S. (2012). Image denoising with multi-layer perceptrons, Part 1: Comparison with existing algorithms and with bounds.
6. Burger, H. C., Schuler, C. J., & Harmeling, S. (2012). Image denoising with multi-layer perceptrons, Part 2: Training trade-offs and analysis of their mechanisms.
7. Ilesanmi, A. E., & Ilesanmi, T. O. (2021). Methods for image denoising using convolutional neural network: A review. *Complex Intell. Syst.*, 7, 2179–2198. <https://doi.org/10.1007/s40747-021-00428-4>
8. Tian, C., Fei, L., Zheng, W., Xu, Y., Zuo, W., & Lin, C.-W. (2020). Deep learning on image denoising: An overview. *Neural Networks*, 131, 251–275. <https://doi.org/10.1016/j.neunet.2020.07.025>
9. Bodhale, V., Vijayalakshmi, M., & Chopra, S. (2025). An efficient image denoising using convolutional neural network. In *Proc. Int. Conf. on Communication and Computational Technologies* (Vol. 1122, pp. 15–27). Springer Nature Singapore.
10. Feng, X., Huang, Q., & Li, X. (2020). Ultrasound image de-speckling by a hybrid deep network with transferred filtering and structural prior. *Neurocomputing*, 414, 346–355. <https://doi.org/10.1016/j.neucom.2020.09.002>
11. Kokil, P., & Sudharson, S. (2020). Despeckling of clinical ultrasound images using deep residual learning. *Computer Methods and Programs in Biomedicine*, 194, 105477. <https://doi.org/10.1016/j.cmpb.2020.105477>
12. Aizenberg, I., & Tovt, Y. (2025). Intelligent frequency domain image filtering based on a multilayer neural network with multi-valued neurons. *Algorithms*, 18, 461. <https://doi.org/10.3390/a18080461>
13. Hasegawa, H. (2021). Advances in ultrasonography: Image formation and quality assessment. *J. Med. Ultrasonics*, 48, 377–389. <https://doi.org/10.1007/s10396-021-01140-z>
14. Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing* (4th Global Ed.). New York: Pearson Education.
15. Aizenberg, I., & Moraga, C. (2007). Multilayer feedforward neural network based on multi-valued neurons (MLMVN) and a backpropagation learning algorithm. *Soft Comput.*, 11, 169–183. <https://doi.org/10.1007/s00500-006-0075-5>
16. Aizenberg, I. (2011). *Complex-Valued Neural Networks with Multi-Valued Neurons*. Studies in Computational Intelligence Series. Berlin: Springer.
17. Grasso, F., Luchetta, A., & Manetti, S. (2018). A multi-valued neuron based complex ELM neural network. *Neural Process. Lett.*, 48, 389–401. <https://doi.org/10.1007/s11063-017-9745-9>

18. Aizenberg, I., & Vasko, A. (2024). Frequency-domain and spatial-domain MLMVN-based convolutional neural networks. *Algorithms*, 17, 361. <https://doi.org/10.3390/a17080361>
19. Bindi, M., Luchetta, A., Lozito, G. M., Carobbi, C. F. M., Grasso, F., & Piccirilli, M. C. (2023). Frequency characterization of medium voltage cables for fault prevention through multi-valued neural networks and power line communication technologies. *IEEE Trans. Power Delivery*, 38, 3227–3237. <https://doi.org/10.1109/TPWRD.2023.3270128>
20. Bindi, M., Piccirilli, M. C., Luchetta, A., Grasso, F., & Manetti, S. (2022). Testability evaluation in time-variant circuits: A new graphical method. *Electronics*, 11, 1589. <https://doi.org/10.3390/electronics11101589>
21. Fink, O., Zio, E., & Weidmann, U. (2014). Predicting component reliability and level of degradation with complex-valued neural networks. *Reliability Engineering & System Safety*, 121, 198–206. <https://doi.org/10.1016/j.res.2013.08.004>
22. Grasso, F., Manetti, S., Piccirilli, M. C., & Reatti, A. (2019). A Laplace transform approach to the simulation of DC–DC converters. *Int. J. Numerical Modelling*, 32, e2618. <https://doi.org/10.1002/jnm.2618>
23. Luchetta, A., Manetti, S., Piccirilli, M. C., Reatti, A., Corti, F., Catelani, M., Ciani, L., & Kazimierczuk, M. K. (2019). MLMVNN for parameter fault detection in PWM DC–DC converters and its applications for buck and boost DC–DC converters. *IEEE Trans. Instrum. Meas.*, 68, 439–449. <https://doi.org/10.1109/TIM.2018.2847978>
24. Nedjah, N., Galindo, J. D. L., Mourelle, L. D. M., & Oliveira, F. D. V. R. D. (2023). Fault diagnosis in analog circuits using swarm intelligence. *Biomimetics*, 8, 388. <https://doi.org/10.3390/biomimetics8050388>
25. Tovt, Y. O., & Bryla, A. Y. (2024). Study of the meaning of weight coefficients of complex-valued neural networks in the frequency domain. *Sci. Bull. of Uzhhorod Univ. Ser. of Math. and Inf.*, 45(2), 259–275. [https://doi.org/10.24144/2616-7700.2024.45\(2\).259-275](https://doi.org/10.24144/2616-7700.2024.45(2).259-275)
26. Aizenberg, E., & Aizenberg, I. (December 2014). Batch linear least squares-based learning algorithm for MLMVN with soft margins. In *Proc. IEEE Symposium on Computational Intelligence and Data Mining (CIDM)*, Orlando, FL: USA. pp. 48–55.

Tovt Yu. O., Bryla A. Yu. Speckle Noise Filtering in Ultrasound Images Using Complex-Valued Neural Networks.

Ultrasound images are widely used in many fields. Their analysis is an extremely important task; therefore, noise filtering in such images plays a crucial role. In this work, we consider the filtering of speckle noise in ultrasound images using complex-valued neural networks. Experiments on noise filtering were conducted, and the obtained results were compared with several well-known speckle noise filtering methods.

Keywords: neural networks, complex-valued neural networks, digital images, noise filtering, speckle noise.

Одержано 27.09.2025