

УДК 004.032.26:004.932.4

DOI [https://doi.org/10.24144/2616-7700.2024.45\(2\).259-275](https://doi.org/10.24144/2616-7700.2024.45(2).259-275)**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>

ДОСЛІДЖЕННЯ ЗМІСТУ ВАГОВИХ КОЕФІЦІЄНТІВ КОМПЛЕКСНОЗНАЧНИХ НЕЙРОМЕРЕЖ У ЧАСТОТНІЙ ОБЛАСТІ

Розглянуто задачу фільтрації зображень за допомогою комплекснозначної нейронної мережі MLMVN у частотній області. Досліджено випадки наявності на зображеннях адитивного Гаусівського шуму та мультиплікативного спекл шуму. Для фільтрації використано комплекснозначну нейромережу прямого поширення. Проведено аналіз вагів коефіцієнтів нейроелементів на різних епохах процесу навчання та зміст ядер згорток утворених з вагів окремих нейроелементів у просторовій області.

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

1. Вступ. Попередня обробка зображень є обов'язковим і дуже важливим інструментом у розпізнаванні та аналізі зображень. Вона дозволяє значно спростити і прискорити процес навчання зосереджуючись саме на важливих деталях а не артефактах, які спотворюють зображення і можуть призвести до некоректних висновків. Не дивлячись на широкий спектр алгоритмів відновлення спотворених зображень у просторовій області велика кількість задач може бути ефективно вирішена саме у частотній області. Яскравими прикладами таких задач є відновлення дефокусованих зображень та фільтрація шумів, що виникають на практиці у різних важливих сферах діяльності людини, зокрема в медицині, аерофотозйомці та супутниковій зйомці. Також можна навести велику кількість прикладів застосування високочастотних та низькочастотних фільтрів, ВМЗД-фільтра [1], фільтра Вінера [2], та інших. Не дивлячись на широко розвинутий інструментарій нейронних мереж, комплекснозначні нейронні мережі ідеально підходять для аналізу зображень саме у частотній області завдяки роботі з комплексними числами. Саме ця особливість дозволяє будувати найбільш точні математичні моделі на основі перетворення Фур'є.

У статті досліджено контекстний зміст вагових коефіцієнтів, що отримані в процесі навчання комплекснозначної нейромережі MLMVN [3] з метою фільтрації шуму на цифрових зображеннях. Також було досліджено їх взаємозв'язок з ядрами фільтрів у просторовій області.

2. Основний результат.

Формат представлення цифрового зображення. Не зменшуючи загальності міркувань для спрощення процесів аналізу та їх інтерпретації було

розглянуто цифрові зображення у відтинках сірого. Зауважимо, що результати аналізу можуть бути адаптовані на випадок кольорових зображень.

У просторовій області цифрове зображення представляється у вигляді дискретної функції двох змінних $f(x, y)$, де x та y — просторові координати, а значенням функції у кожній точці простору є інтенсивність [4]. Оскільки дослідження проводилися у частотній області, то для переходу між просторовою та частотною областями було використано пряме та зворотне перетворення Фур'є.

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-i2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)},$$

$$f(x, y) = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) e^{i2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)}.$$

З метою оптимізації обчислень у роботі для переходу у частотну область використано алгоритм швидкого двомірного перетворення Фур'є (FFT) [5].

Моделювання досліджуваних зашумлених цифрових зображень. З метою формування навчальної вибірки для алгоритмів навчання комплекснозначних нейромереж було змодельовано навчальну вибірку з штучно зашумленими зображеннями. При цьому було використано найбільш поширені на практиці адитивний Гаусівський шум [6] та мультиплікативний спекл шум [7]. Для реалізації моделювання шуму використовувалися відповідні функції Matlab з пакету Image Processing Toolbox.

Гаусівський шум зазвичай має нормальний розподіл і часто виникає наприклад внаслідок електронних перешкод у фотосенсорах, а також під час отримання цифрових зображень при недостатньому рівні освітлення. Адитивний Гаусівський шум у даному дослідженні моделювався наступним чином:

$$f_{noisy}(x, y) = f(x, y) + n(x, y),$$

де $f_{noisy}(x, y)$ — зашумлене зображення, $f(x, y)$ — ідеальне зображення, $n(x, y)$ — випадковий шум з нормальним розподілом інтенсивностей.

Для моделювання адитивного Гаусівського шуму використовувався шум зі стандартним відхиленням у межах 0.1σ – 0.3σ (де σ — стандартне відхилення інтенсивностей пікселів кожного окремо взятого ідеального зображення).

Спекл шум часто виникає внаслідок когерентності хвиль, які взаємодіють з неоднорідностями в середовищі. Цей шум є типовим для ультразвукових та радіолокаційних зображень. У роботі було змодельовано рівномірний мультиплікативний спекл шум

$$f_{noisy}(x, y) = f(x, y) \cdot n(x, y),$$

де $f_{noisy}(x, y)$ — зашумлене зображення, $f(x, y)$ — ідеальне зображення, $n(x, y)$ — випадковий шум з рівномірним розподілом інтенсивностей.

При моделюванні мультиплікативного спекл-шуму стандартне відхилення шуму варіювалось у діапазоні 0.1σ – 0.4σ .

Важливо зауважити, що шум був змодельований таким чином, щоб середні значення інтенсивності (середня інтенсивність) ідеального та зашумленого

зображення були рівними. Це дозволяє забезпечити збереження середньої інтенсивності зображення після додавання шуму, що є критичним для коректного аналізу впливу шуму та подальших методів його фільтрації. У процесі навчання та валідації для оцінки якості фільтрації було використано оцінку максимального відношення сигнал\шум (PSNR).

Загальна схема навчання комплекснозначної нейронної мережі. Як було зазначено раніше, для обробки зображень у частотній області найбільш оптимальним вибором є використання нейромереж, у яких входи, виходи та ваги нейронів є комплексними числами. Такі нейронні мережі називають комплекснозначними. Алгоритми навчання комплекснозначних нейромережам всебічно розглянуті у численних публікаціях [3, 8, 9, 10, 11].

У роботі для формування навчальної вибірки було використано множину зображень у відтинках сірого різних розмірів. Процес навчання нейронної мережі був організований із застосуванням підходу навчання з валідацією. Для цього змодельована навчальна вибірка була поділена на дві частини: власне навчальну вибірку, яка використовувалася для коригування ваг нейронів, та валідаційну вибірку, яка застосовувалася для періодичної перевірки результату навчання. Навчальна вибірка складалася з пар ідеальних та зашумлених векторизованих фрагментів зображень у частотній області. Потужність навчальної вибірки становила 60 000 навчальних зразків.

Процес навчання був проведений окремо для адитивного Гаусівського шуму та мультиплікативного спекл-шуму, однак загальна процедура формування навчальних вибірок і підхід до навчання були однаковими для обох типів шуму. Для перевірки якості навчання нейромережі використовувалася валідаційна вибірка. Вона складалася з пар ідеальних та зашумлених зображень, які не входили до навчальної вибірки.

Для фільтрації шуму на цифрових зображеннях використовувалася комплекснозначна нейронна мережа прямого поширення, яка має n входів, один прихований шар із N_{h_1} нейронами та вихідний шар із N_o нейронами. Архітектура цієї нейромережі була обрана на основі емпіричних даних. При цьому слід зауважити, що кількість прихованих шарів і нейронів, які використовувалися в даному дослідженні, не можна вважати оптимальною. Оптимізація цих параметрів є предметом подальших досліджень.

Навчання мережі проводилося з використанням алгоритму навчання пакетами (batch learning) [10, 11]. Основною перевагою цього методу порівняно з класичним алгоритмом навчання для комплекснозначних нейромереж є можливість одночасно коригувати ваги нейронів прихованого та вихідного шарів на основі декількох навчальних зразків. Навчання проводилося до моменту досягнення бажаного значення PSNR на валідаційній вибірці або досягнення наперед заданої кількості епох навчання.

Аналіз ваг нейронів сформованих у процесі навчання. Навчання нейромережі є ітеративним процесом, на кожному кроці якого обчислюється похибка мережі та похибка кожного нейроелемента, після чого, згідно з правилом навчання, оновлюються ваги нейроелементів. Таким чином ваги синапсів нейронів є одним із найважливіших факторів, які впливають на їхній вихід, а відповідно й на вихід нейромережі загалом.

Розглянемо k -й нейроелемент першого прихованого шару комплекснозначної

нейромережі. Вихід цього нейрона обчислюється за формулою:

$$O_1^{(k)} = P \left(\sum_{i=0}^n w_i^{(k)} x_i^{(p)} \right),$$

де $P(\cdot)$ — активаційна функція, $w_0^{(k)}, w_1^{(k)}, w_2^{(k)}, \dots, w_n^{(k)}$ — ваги нейрона ($w_0^{(k)}$ називається вільною вагою), $x_0^{(p)}, x_1^{(p)}, \dots, x_n^{(p)}$ — входи нейрона ($x_0^{(p)}$ — штучний вхід, який завжди рівний 1).

Попередню формулу можна записати у наступному вигляді:

$$O_1^{(k)} = P \left(w_0^{(k)} x_0^{(p)} + \sum_{i=1}^n w_i^{(k)} x_i^{(p)} \right) = P \left(w_0^{(k)} x_0^{(p)} + R^{(k,p)} \right),$$

$R^{(k,p)}$ є сумою елементів вектора, який є результатом поелементного добутку векторів $w^{(k)} = (w_1^{(k)}, w_2^{(k)}, \dots, w_n^{(k)})$ та $x^{(p)} = (x_1^{(p)}, \dots, x_n^{(p)})$. Як зазначено вище, на вхід нейромережі, а відповідно й на кожен нейрон першого прихованого шару, подаються векторизовані фрагменти зображення у частотній області. Оскільки фрагмент зображення у просторовій області можна розглядати як дискретну функцію двох змінних, його можна записати у вигляді матриці, де кожен елемент є інтенсивністю у відповідних просторових координатах. Таким чином, при переході у частотну область (за допомогою двовимірного швидкого перетворення Фур'є) отримуємо матрицю коефіцієнтів перетворення Фур'є такого ж розміру, як і фрагмент зображення. З вищенаведеного випливає, що вектор $x^{(p)}$ так само як і $w^{(k)}$, можуть бути записані у вигляді матриць

$$X_f^{(p)} = \begin{pmatrix} x_1^{(p)} & x_1^{(p)} & \cdots & x_{r_1}^{(p)} \\ x_{r_1+1}^{(p)} & x_{r_1+2}^{(p)} & \cdots & x_{r_2}^{(p)} \\ \vdots & \vdots & \ddots & \vdots \\ x_{r_2+1}^{(p)} & x_{r_2+2}^{(p)} & \cdots & x_n^{(p)} \end{pmatrix}, \quad W_f^{(k)} = \begin{pmatrix} w_1^{(k)} & w_1^{(k)} & \cdots & w_{r_1}^{(k)} \\ w_{r_1+1}^{(k)} & w_{r_1+2}^{(k)} & \cdots & w_{r_2}^{(k)} \\ \vdots & \vdots & \ddots & \vdots \\ w_{r_2+1}^{(k)} & w_{r_2+2}^{(k)} & \cdots & w_{r_n}^{(k)} \end{pmatrix}.$$


Оскільки обробка відбувається у частотній області, то, згідно з теоремою згортки [13], можемо записати таке:

$$X_s^{(p)} * W_s^{(k)} = \mathcal{F}^{-1} \left(X_f^{(p)} \times W_f^{(k)} \right),$$

де $\mathcal{F}^{-1}(\cdot)$ — обернене двомірне перетворення Фур'є, $*$ — оператор згортки, \times — оператор поелементного множення, $X_s^{(p)} = \mathcal{F}^{-1} \left(X_f^{(p)} \right)$, $W_s^{(k)} = \mathcal{F}^{-1} \left(W_f^{(k)} \right)$.

З останньої рівності випливає, що $R^{(k,p)}$ є сумою елементів згортки у просторовій області фрагменту зображення $X_s^{(p)}$ з ядром $W_s^{(k)}$.

У таблицях 1–6 наведено результати згорток у просторовій області вхідних фрагментів зображень з ядрами, сформованими вагами різних нейронів першого прихованого шару при навчанні мережі для фільтрації Гаусівського та спекл шуму.




а) #1. Гаусівський шум
 $0.1\sigma-0.3\sigma$;



б) #2. Гаусівський шум
 $0.1\sigma-0.3\sigma$;



в) #3. Гаусівський шум
 $0.1\sigma-0.3\sigma$;



г) #1. Спекл шум
 $0.1\sigma-0.4\sigma$;



д) #2. Спекл шум
 $0.1\sigma-0.4\sigma$;




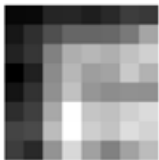
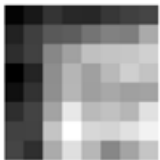












е) #3. Спекл шум
 $0.1\sigma-0.4\sigma$.

Рис. 1. Фрагмент зашумленого зображення розміром 8×8 .




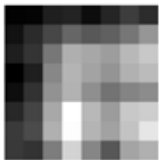
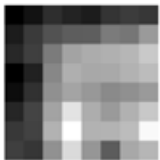
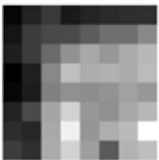









Таблиця 1.

Результати згортки у просторовій області зображення #1 (рис. 1 (а)) з ядрами, що утворюються вагами нейронів першого прихованого шару

	Епоха навчання #1	Епоха навчання #5	Епоха навчання #10
Нейрон #1			
Нейрон #256			
Нейрон #512			
Нейрон #768			
Нейрон #1024			




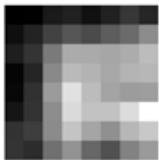
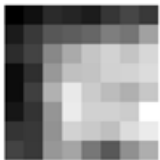
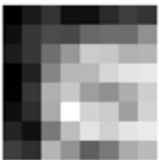
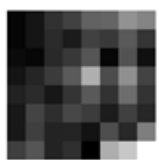


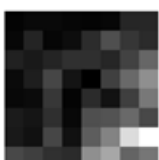





Таблиця 2.

Результати згортки у просторовій області зображення #2 (рис. 1 (б)) з ядрами, що утворюються вагами нейронів першого прихованого шару

	Епоха навчання #1	Епоха навчання #5	Епоха навчання #10
Нейрон #1			
Нейрон #256			
Нейрон #512			
Нейрон #768			
Нейрон #1024			


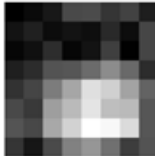













Таблиця 3.

Результати згортки у просторовій області зображення #3 (рис. 1 (в)) з ядрами, що утворюються вагами нейронів першого прихованого шару

	Епоха навчання #1	Епоха навчання #5	Епоха навчання #10
Нейрон #1			
Нейрон #256			
Нейрон #512			
Нейрон #768			
Нейрон #1024			
















Таблиця 4.

Результати згортки у просторовій області зображення #4 (рис. 1 (г)) з ядрами, що утворюються вагами нейронів першого прихованого шару

	Епоха навчання #1	Епоха навчання #7	Епоха навчання #9
Нейрон #1			
Нейрон #256			
Нейрон #512			
Нейрон #768			
Нейрон #1024			

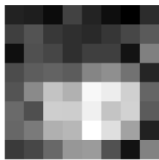
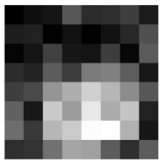
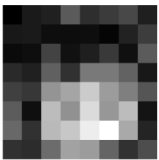


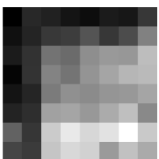


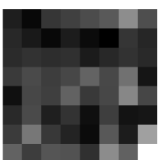


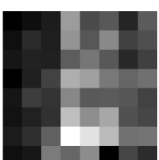



Таблиця 5.

Результати згортки у просторовій області зображення #5 (рис. 1 (д)) з ядрами, що утворюються вагами нейронів першого прихованого шару

	Епоха навчання #1	Епоха навчання #7	Епоха навчання #9
Нейрон #1			
Нейрон #256			
Нейрон #512			
Нейрон #768			
Нейрон #1024			

Таблиця 6.

Результати згортки у просторовій області зображення #6 (рис. 1 (e)) з ядрами, що утворюються вагами нейронів першого прихованого шару

	Епоха навчання #1	Епоха навчання #7	Епоха навчання #9
Нейрон #1			
Нейрон #256			
Нейрон #512			
Нейрон #768			
Нейрон #1024			

Доцільно також порівняти ядра згортки, сформовані вагами нейронів, із деякими відомими ядрами згортки у просторовій області. Для порівняння використовувалася косинусна подібність.

$$s(A, B) = \frac{\Re(\langle A, B \rangle)}{\|A\| \|B\|},$$

де A та B — векторизовані ядра згортки, $\langle \cdot \rangle$ — скалярний добуток, $\Re(\cdot)$ — функція, яка повертає дійсну частину комплексного числа, $\|\cdot\|$ — норма Фробеніуса. Значення $s(A, B)$ близькі до 1 свідчать про подібність ядер згортки.

У таблицях 7 та 8 наведено результати порівняння ядер згортки у просторовій області, отриманих з ваг нейронів комплекснозначної нейромережі на 10-й епісі навчання для фільтрації Гаусівського шуму (таблиця 7) та спекл-шуму (таблиця 8) з деякими відомими ядрами згортки у просторовій області.

Таблиця 7.

Порівняння ядер згортки, що утворюються вагами нейронів з деякими відомими ядрами згортки в просторовій області

	Бокс фільтр, 8×8	Гаусівський фільтр, 8×8, стандартне відхилення 0.5	Гаусівський фільтр, 8×8, стандартне відхилення 1
Нейрон #1	0.022833	-0.18097	-0.14759
Нейрон #256	0.062074	-0.047544	-0.042503
Нейрон #512	0.048572	-0.063726	-0.025157
Нейрон #768	0.0036742	-0.083041	-0.11821
Нейрон #1024	0.038796	-0.091296	-0.054479

Таблиця 8.

Порівняння ядер згортки, що утворюються вагами нейронів з деякими відомими ядрами згортки в просторовій області

	Бокс фільтр, 8×8	Гаусівський фільтр, 8×8, стандартне відхилення 0.5	Гаусівський фільтр, 8×8, стандартне відхилення 1
Нейрон #1	0.020731	-0.18133	-0.12566
Нейрон #256	0.065181	-0.15032	-0.098496
Нейрон #512	0.050016	-0.024569	-0.017305
Нейрон #768	-0.0096031	-0.028489	-0.011391
Нейрон #1024	0.047493	-0.053494	-0.026364

У таблицях 9–14 наведено результати фільтрації зашумлених зображень за допомогою відомих методів фільтрації. Зображення з номерами 1,2,3 містять адитивний Гаусівський шум із стандартним відхиленням 0.1σ , 0.2σ та 0.3σ (де σ — стандартне відхилення кожного окремо взятого ідеального зображення) відповідно. Зображення з номерами 4,5 та 6 містять мультиплікативний спекл шум зі стандартним відхиленням 0.2σ , 0.3σ та 0.4σ відповідно. У таблицях 15–19 наведено результати згортки зображень з номерами 1–6 з ядром, сформованим з ваг комплекснозначного нейроелемента.

Таблиця 9.

Фільтрація зображень з використанням VM3D фільтра

Зображення #1	32.3497	0.77856	0.9961
Зображення #2	29.4844	0.627	0.983
Зображення #3	25.7033	0.51686	0.96354
Зображення #4	30.7613	0.76866	0.99502
Зображення #5	28.8852	0.60848	0.98245
Зображення #6	22.2808	0.44534	0.958

Таблиця 10.

Фільтрація зображень з використанням Frost фільтра з ядром розміру 3×3

	PSNR	SSIM	Кореляція
Зображення #4	28.3072	0.76486	0.99069
Зображення #5	26.2537	0.60972	0.97556
Зображення #6	22.6432	0.5086	0.95369

Таблиця 11.

Фільтрація зображень з використанням Lee фільтра з ядром розміру 3×3

	PSNR	SSIM	Кореляція
Зображення #4	29.5624	0.78081	0.99319
Зображення #5	27.7981	0.66759	0.983
Зображення #6	23.6314	0.62605	0.9689

Таблиця 12.

Фільтрація зображень з використанням Гаусівського фільтра розміром 3×3

	PSNR	SSIM	Кореляція
Зображення #1	28.792	0.75903	0.99126
Зображення #2	27.1301	0.64375	0.97459
Зображення #3	24.5305	0.62553	0.96113
Зображення #4	28.9979	0.8114	0.99217
Зображення #5	26.7999	0.69389	0.97962
Зображення #6	23.2128	0.6139	0.96229

Таблиця 13.

Фільтрація зображень з використанням mean фільтра

	PSNR	SSIM	Кореляція
Зображення #1	27.5266	0.69113	0.98822
Зображення #2	26.1626	0.54263	0.96654
Зображення #3	23.4641	0.51558	0.94956
Зображення #4	27.7646	0.75651	0.98935
Зображення #5	25.931	0.60199	0.97281
Зображення #6	22.4884	0.50564	0.95102

Таблиця 14.

Фільтрація зображень з використанням median фільтру

	PSNR	SSIM	Кореляція
Зображення #1	28.9261	0.70792	0.99131
Зображення #2	26.4753	0.54488	0.9705
Зображення #3	24.0154	0.50745	0.95491
Зображення #4	29.5767	0.78316	0.99248
Зображення #5	27.279	0.60831	0.97708
Зображення #6	22.2505	0.50074	0.95563

Таблиця 15.

Згортка з ядром сформованим з ваг нейрона #1 першого прихованого шару

	PSNR	SSIM	Кореляція
Зображення #1	9.679	0.14058	0.75555
Зображення #2	11.1107	0.039981	0.62206
Зображення #3	7.1767	-0.009568	0.32788
Зображення #4	9.7986	0.17531	0.76509
Зображення #5	11.3959	0.060549	0.65415
Зображення #6	7.0937	-0.012968	0.34234

Таблиця 16.

Згортка з ядром сформованим з ваг нейрона #256 першого прихованого шару

	PSNR	SSIM	Кореляція
Зображення #1	15.2185	0.28548	0.88255
Зображення #2	20.0616	0.21385	0.85416
Зображення #3	14.4664	0.16622	0.67291
Зображення #4	15.2535	0.33429	0.88482
Зображення #5	19.737	0.24288	0.8664
Зображення #6	13.757	0.14491	0.68519

Таблиця 17.

Згортка з ядром сформованим з ваг нейрона #512 першого прихованого шару

	PSNR	SSIM	Кореляція
Зображення #1	15.9611	0.31671	0.93556
Зображення #2	20.8287	0.16441	0.87298
Зображення #3	14.6615	0.14323	0.78444
Зображення #4	16.7474	0.39105	0.93785
Зображення #5	21.1445	0.20906	0.88693
Зображення #6	14.9326	0.12511	0.79323

Таблиця 18.

Згортка з ядром сформованим з ваг нейрона #768 першого прихованого шару

	PSNR	SSIM	Кореляція
Зображення #1	7.3852	0.090734	0.11664
Зображення #2	6.5666	0.044863	-0.11016
Зображення #3	3.7031	0.01698	-0.14104
Зображення #4	7.491	0.091222	0.24199
Зображення #5	6.6837	0.050447	-0.010282
Зображення #6	3.9845	0.022352	-0.015933

Таблиця 19.

Згортка з ядром сформованим з ваг нейрона #1024 першого прихованого шару

	PSNR	SSIM	Кореляція
Зображення #1	9.8989	0.21524	0.80256
Зображення #2	9.5571	0.17998	0.70795
Зображення #3	7.0918	0.14029	0.53676
Зображення #4	9.9547	0.24695	0.80882
Зображення #5	9.7059	0.20776	0.73009
Зображення #6	7.4643	0.12938	0.54255

Зі значень PSNR та SSIM [14] (таблиці 15–19) видно, що ядра згорток не забезпечують фільтрацію шуму на достатньому рівні (значення PSNR менше 20dB вважається низьким) і не наближаються за якістю фільтрації до жодного з наведених методів. У більшості випадків зберігся середній рівень кореляції між результатом згортки та ідеальним зображенням, що свідчить про збереження певного рівня подібності між ними.

3. Висновки. У роботі було проведено дослідження вагів комплекснозначної нейромережі MLMVN у процесі навчання з метою фільтрації зображень, на яких присутній адитивний Гаусівський шум та мультиплікативний спекл шум. Зроблено аналіз окремих нейроелементів на різних епохах навчання. Проведені дослідження дозволяють зробити висновок, що ядра згорток утворених з ваг окремих нейроелементів не дозволяють сформувати ефективні фільтри у просторовій області і не є близькими до відомих методів фільтрації. Проте ваги нейронів акумулюють інформацію отриману в процесі навчання, що дозволяє нейромережі здійснювати реальну успішну фільтрацію шуму на цифрових зображеннях.

Список використаної літератури

1. Dabov K., Foi A., Katkovnik V., Egiazarian K. Image denoising by sparse 3-D Transform-Domain collaborative filtering. *IEEE Transactions on Image Processing*. 2007. Vol. 16, No. 8, P. 2080–2095. DOI: <https://doi.org/10.1109/tip.2007.901238>
2. Wiener N. Extrapolation, interpolation, and smoothing of stationary time series: With Engineering Applications. The M.I.T. Press : Cambridge, Massachusetts, 1949. 158 p.
3. Aizenberg I., Moraga C. Multilayer feedforward neural network based on multi-valued neurons (MLMVN) and a backpropagation learning algorithm. *Soft Computing*. 2006. Vol. 11, No. 2. P. 169–183. DOI: <https://doi.org/10.1007/s00500-006-0075-5>

4. Gonzalez R. C., Woods R. E. *Digital Image Processing, Global Edition*. Pearson Education : UK, 2018. pp. 18–19.
5. Cooley J. W., Tukey J. W. An algorithm for the machine calculation of complex fourier series. *Mathematics of Computation*. 1965. Vol. 19, No. 90. P. 297–301. DOI: <https://doi.org/10.2307/2003354>
6. Jahan I. A Comparative study of Gaussian noise removal methodologies for gray scale images. *International Journal of Computer Applications*. 2017. Vol. 172, No. 5. P. 1–6. DOI: <https://doi.org/10.5120/ijca2017915138>
7. Pradeep S., Nirmaladevi P. A Review on Speckle Noise Reduction Techniques in Ultrasound Medical images based on Spatial Domain, Transform Domain and CNN Methods. *International Virtual Conference on Robotics, Automation, Intelligent Systems and Energy*. Erode : India, 2021. Vol. 1055, No. 1. 012116. DOI: <https://doi.org/10.1088/1757-899x/1055/1/012116>
8. Aizenberg I. Hebbian and error-correction learning for complex-valued neurons. *Soft Computing*. 2012. Vol. 17, No. 2. P. 265–273. DOI: <https://doi.org/10.1007/s00500-012-0891-8>
9. Bindi M., Luchetta A., Lozito G. M., Carobbi C. F. M., Grasso F., Piccirilli M. C. Frequency characterization of medium voltage cables for fault prevention through Multi-Valued neural networks and power line communication technologies. *IEEE Transactions on Power Delivery*. 2023. Vol. 38, No. 5. P. 3227–3237. DOI: <https://doi.org/10.1109/tpwrd.2023.3270128>
10. Aizenberg I., Luchetta A., Manetti S. A modified learning algorithm for the multilayer neural network with multi-valued neurons based on the complex QR decomposition. *Soft Computing*. 2011. Vol. 16, No. 4. P. 563–575. DOI: <https://doi.org/10.1007/s00500-011-0755-7>
11. Aizenberg E., Aizenberg I. Batch linear least squares-based learning algorithm for MLMVN with soft margins. *IEEE Symposium on Computational Intelligence and Data Mining (CIDM)*. Orlando : USA, 2014. DOI: <https://doi.org/10.1109/cidm.2014.7008147>
12. Lawson C. L., Hanson R. J. Solving least squares problems. SIAM : USA, 1995. 349 p. DOI: <https://doi.org/10.1137/1.9781611971217>
13. Gonzalez R. C., Woods R. E. *Digital Image Processing, Global Edition*. Pearson Education : UK, 2018. pp. 213–214.
14. Sara U., Akter M., Uddin M. S. Image Quality Assessment through FSIM, SSIM, MSE and PSNR — A Comparative Study. *Journal of Computer and Communications*. 2019. Vol. 7, No. 3. P. 8–18. DOI: <https://doi.org/10.4236/jcc.2019.73002>

Tovt Yu. O., Bryla A. Yu. Study of the content of weights of complex-valued neural networks in frequency domain.

The problem of image filtering using complex-valued neural networks in the frequency domain is considered. The cases of the presence of additive Gaussian noise and multiplicative speckle noise in images are investigated. A complex-valued feedforward neural network is used for filtering. The weights of the neurons at different epochs of the learning process and the content of convolution kernels formed from the weights of individual neurons in the spatial domain are analysed.

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

References

1. Dabov, K., Foi, A., Katkovnik, V., & Egiazarian, K. (2007). Image denoising by sparse 3-D Transform-Domain collaborative filtering. *IEEE Transactions on Image Processing*, 16(8), 2080–2095. <https://doi.org/10.1109/tip.2007.901238>
2. Wiener, N. (1949). *Extrapolation, interpolation, and smoothing of stationary time series: With Engineering Applications*. The M.I.T. Press: Cambridge, Massachusetts.
3. Aizenberg, I., & Moraga, C. (2006). Multilayer feedforward neural network based on multi-valued neurons (MLMVN) and a backpropagation learning algorithm. *Soft Computing*, 11(2), 169–183. <https://doi.org/10.1007/s00500-006-0075-5>
4. Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing, Global Edition*. (pp. 18–19). Pearson Education: UK.

5. Cooley, J. W., & Tukey, J. W. (1965). An algorithm for the machine calculation of complex fourier series. *Mathematics of Computation*, 19(90), 297–301. <https://doi.org/10.2307/2003354>
6. Jahan, I. (2017). A Comparative study of Gaussian noise removal methodologies for gray scale images. *International Journal of Computer Applications*, 172(5), 1–6. <https://doi.org/10.5120/ijca2017915138>
7. Pradeep, S., & Nirmaladevi, P. (2021). A Review on Speckle Noise Reduction Techniques in Ultrasound Medical images based on Spatial Domain, Transform Domain and CNN Methods. *International Virtual Conference on Robotics, Automation, Intelligent Systems and Energy*. Erode: India. 1055(1). <https://doi.org/10.1088/1757-899x/1055/1/012116>
8. Aizenberg, I. (2012). Hebbian and error-correction learning for complex-valued neurons. *Soft Computing*, 17(2), 265–273. <https://doi.org/10.1007/s00500-012-0891-8>
9. 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 Transactions on Power Delivery*, 38(5), 3227–3237. <https://doi.org/10.1109/tpwrld.2023.3270128>
10. Aizenberg, I., Luchetta, A., & Manetti, S. (2011). A modified learning algorithm for the multilayer neural network with multi-valued neurons based on the complex QR decomposition. *Soft Computing*, 16(4), 563–575. <https://doi.org/10.1007/s00500-011-0755-7>
11. Aizenberg, E., & Aizenberg, I. (2014). Batch linear least squares-based learning algorithm for MLMVN with soft margins. *IEEE Symposium on Computational Intelligence and Data Mining (CIDM)*. Orlando: USA. <https://doi.org/10.1109/cidm.2014.7008147>
12. Lawson, C. L., & Hanson, R. J. (1995). *Solving least squares problems*. SIAM: USA. <https://doi.org/10.1137/1.9781611971217>
13. Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing, Global Edition*. (pp. 213–214). Pearson Education: UK.
14. Sara, U., Akter, M., & Uddin, M. S. (2019). Image Quality Assessment through FSIM, SSIM, MSE and PSNR — A Comparative Study. *Journal of Computer and Communications*, 7(3), 8–18. <https://doi.org/10.4236/jcc.2019.73002>

Одержано 25.10.2024